

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA

DEPARTAMENTO DE OBRAS CIVILES

SANTIAGO DE CHILE




# DESARROLLO DE HERRAMIENTAS DE VISUALIZACIÓN DE APLICACIONES DE MACHINE LEARNING EN MODELOS DE COMPORTAMIENTO DE PAVIMENTOS

**Camila Paz Díaz Brito**

MEMORIA DE TITULACIÓN PARA OPTAR AL TÍTULO DE INGENIERO  
CIVIL

Profesores Guía: Alelí Osorio y Gabriel García

MARZO DE 2021



## AGRADECIMIENTOS

*En primer lugar, agradezco la entrega de mi profesora Alelí Osorio, por su constante apoyo en el desarrollo de mi memoria, por preocuparse de mi bienestar tanto personal como académico. También agradezco que, junto con el profesor Gabriel García, en ningún momento me dejaran sola en el proceso y estuvieron siempre dispuestos a guiarme y darme esa frase de aliento cada vez que fue necesaria.*

*A mi compañero Andrés Montecinos por motivarme en el inicio del estudio, por su buena disposición y sabiduría.*

*A los profesores del Departamento de Obras Civiles por entregarnos las herramientas necesarias para enfrentar el mundo laboral.*



*A mi psicóloga Melody Cid que me enseñó a quererme, valorarme y confiar en mis capacidades. Me dio las fuerzas para salir de mi zona de confort y enfrentarlo dando siempre lo mejor de mí.*

*A mi familia por estar siempre presente e incitarme a nunca rendirme.*

*Muchas gracias a mis amigos de la universidad: Patricio, Lore, Walter, Cris, Juli, Brune, Cony, Ferni, y muchos más con los que compartimos horas de estudios, onces con mi familia, abrazos de logros y también muy buenos momentos que no olvidaré.*

*Mis agradecimientos a mis amigas del colegio y a mis amigos Eduardo, Nicolás y Rodrigo por motivarme siempre y considerarme ya por más de diez años y estar presente a pesar del tiempo.*

*A mi Felipe que me demostró que puedo ser aún más feliz de lo que creía.*



---

## DEDICATORIA

*Para mis padres Carlos e Ingrid que pusieron de todo su esfuerzo para verme llegar a este momento, me entregaron las herramientas necesarias para ser hoy una gran profesional. Su amor y apoyo incondicional es impagable.*

*A mi hermanita Consuelo, que desde que vi sus ojitos me entregó una paz que me ha acompañado hasta el día de hoy. Gracias hermanita por esa complicidad, alegría y amor infinito.*

*A mi Felipe, porque sin tu amor y ayuda nada de esto habría sido lo mismo. Muchas gracias por tu compañía, confianza y por darme el ánimo que me incita a desafiarme y crecer cada día.*



*A mi perrita Ary que me acompañó en todo el proceso con sus travesuras, lengüetazos y sus sueños alocados al dormir a mi lado,*

*A mis abuelos por darme ese abrazo esperanzador y motivarme siempre a ser mejor persona y cumplir mis metas.*

*A Patricio por ser ese abrazo y oído necesario en muchas ocasiones. A Pilar por no despegarse de mi lado a pesar de la adversidad. A Valeria por permitir desconectarme cada vez que lo necesité y por siempre confiar en mí. A Loreto por ser esa frase de apoyo y alegría constante. A Julián por apañar incondicionalmente.*

*A los amigos que nos hicimos en cada paseo con Ary, en especial a nuestras mejores amigas Hili y Sami, por ser ese apoyo necesario en todas las mañanas para comenzar cada día motivadas y felices.*

*A mí por nunca rendirme y seguir mis sueños. ¡Voy por mucho más!*





## RESUMEN

Los Sistemas de Gestión de Pavimentos (SGP) son conjuntos de herramientas analíticas que ayuda a la toma de decisiones de redes de pavimentos; su fin principal es hacer un seguimiento y continua evaluación de los activos viales disponibles para que proporcionen seguridad y confort a los usuarios (Kargah-Ostadi, 2014; Hernan Solminihac et al., 2018). Un SGP debe desarrollar programas de priorización de mantenimiento y rehabilitación de pavimentos dentro del activo vial disponible, el cual dependerá del nivel de decisión que requiera el sector: nivel de red para umbrales de condición general y nivel de proyecto con datos más detallados y precisos. En ambos casos se requieren modelos de comportamiento precisos que predigan el deterioro de los pavimentos en función del tiempo y definir estrategias de mantenimiento y rehabilitación óptimas. (Osorio-Lird et al., 2018).

Generalmente, los modelos de comportamiento se desarrollan usando fórmulas funcionales continuas mediante técnicas clásicas como las regresiones y enfoques probabilísticos como cadenas de Markov; sin embargo, estos modelos son subjetivos, con dificultad de calibrar a condiciones distintas a las originales, y, además, requieren información histórica del pavimento (Hernan Solminihac et al., 2018). Actualmente, hay mayor interés por desarrollar modelos aplicando técnicas de Aprendizaje Automático (ML, Machine Learning) puesto que es una herramienta de programación, basado en métodos estadísticos, que utiliza datos de ejemplos o experiencias pasadas para optimizar un criterio de rendimiento automático y tiene la capacidad de adaptarse cuando las condiciones cambian en el tiempo (Alpaydin, 2010; R. Y. Choi et al., 2020). Las herramientas de ML más comunes son: Red Neuronal Artificial (ANN, Artificial Neural Network), regresión lineal y logística, Árbol de Decisión (DT, Decision Tree), Bosque Aleatorio (RF, Random Forest), Máquina de Vectores de Soporte (SVM, Support Vector Machine), Programación Genética (GP, Genetic Programming), entre otros.

Las herramientas de ML han proporcionado una solución conveniente y precisa para problemas de todos los campos, proyectándola como una buena alternativa para modelos de deterioro de pavimentos. El aumento en la investigación genera varias alternativas; por lo que no es simple decidir cuál será la herramienta de ML más conveniente para modelar el deterioro de pavimentos, cuál ayudará a tener un modelo más preciso y generalizable y cuál será la herramienta que más se ajusta a las condiciones y objetivos particulares.

El presente estudio hará una búsqueda detallada de las herramientas de ML aplicadas a modelos de deterioro estudiando las metodologías de modelamiento, las consideraciones tomadas, las ventajas y desventajas, los requisitos y los resultados de los modelos. Para luego, generar un software útil y versátil que permitirá definir la herramienta más adecuada para predecir teniendo en consideración el nivel de estudio, tipo de pavimento, proyección de predicción, variables de entrada y salida más usadas, datos disponibles, etc. Además, permitirá visualizar las oportunidades de investigación para aplicar herramientas de ML en modelos de condición de pavimentos.



---



## ABSTRACT

The Pavement Management Systems (PMS) are sets of analytical tools that help to make decisions about pavement networks; its main purpose is to monitor and continually evaluate the road assets available so that they provide safety and comfort to users (Kargah-Ostadi, 2014; Hernan Solminihac et al., 2018). An SGP must develop prioritization programs for maintenance and rehabilitation of pavements within the available road asset, which will depend on the level of decision required by the sector: network level for general condition thresholds and project level with more detailed and accurate data. In both cases, precise behavioral models are required to predict the deterioration of pavements as a function of time and define optimal maintenance and rehabilitation strategies. (Osorio-Lird et al., 2018).

Generally, behavior models are developed using continuous functional formulas using classical techniques such as regressions and probabilistic approaches such as Markov chains; However, these models are subjective, with difficulty to calibrate to conditions other than the original ones, and, in addition, they require historical information on the pavement (Solminihac et al., 2018). Currently, there is greater interest in developing models by applying Machine Learning (ML) techniques since it is a programming tool, based on statistical methods, that uses data from examples or past experiences to optimize an automatic performance criterion and has the ability to adapt when conditions change over time (Alpaydin, 2010; RY Choi et al., 2020). The most common ML tools are Artificial Neural Network (ANN), linear and logistic regression, Decision Tree (DT), Random Forest (RF), Support Vector Machine (SVM), Genetic Programming (GP), among others.



ML tools have provided a convenient and necessary solution to problems in all fields, projecting it as a good alternative for pavement deterioration models. The increase in research generates several alternatives, so it is not easy to decide which will be the most convenient ML tool to model the pavement deterioration, what will be more precise and generalizable model and which will be the tool that best suits the particular condition and objectives.

This study will make a detailed search to ML tools applied to impairment models, studying the modeling methodologies, the considerations taken, the advantages and disadvantages, the requirements and the results to the models. In order to later, generate a useful and versatile software that defines the most appropriate tool to predict taking into account the study level, type of pavement, prediction projection, most used input and output variables, available data, etc. visualize research opportunities to apply ML tools in pavement performance models.





## TABLA DE CONTENIDOS



|  |      |
|--|------|
| AGRADECIMIENTOS .....  | i    |
| DEDICATORIA .....  | ii   |
| RESUMEN .....  | iii  |
| ABSTRACT .....   | iv   |
| TABLA DE CONTENIDOS .....  | v    |
| ÍNDICE DE FIGURAS .....  | viii |
| ÍNDICE DE GRÁFICOS .....   | x    |
| ÍNDICE DE TABLAS .....   | x    |
| LISTA DE ABREVIACIONES .....   | xii  |
| CAPÍTULO 1. INTRODUCCIÓN .....   | 1    |
| 1.1    Objetivos Generales .....   | 2    |
| 1.2    Objetivos Específicos .....                                       | 2    |
| 1.3    Alcance del estudio .....   | 2    |
| CAPÍTULO 2. MARCO TEÓRICO .....  | 3    |
| 2.1    GESTIÓN DE INFRAESTRUCTURA VIAL .....                             | 3    |
| 2.1.1    Sistema de gestión de pavimentos .....                          | 3    |
| 2.1.2    Gestión Actual .....  | 4    |
| 2.1.3    Inventario .....  | 6    |
| 2.1.4    Pre-procesamiento de datos .....                                | 11   |
| 2.1.5    Mantenimiento, Rehabilitación y Reconstrucción .....            | 14   |
| 2.2    EVALUACIÓN DE CONDICIÓN DE PAVIMENTOS .....                       | 14   |
| 2.2.1    Definición y característica de los Pavimentos .....             | 14   |
| 2.3    MODELOS DE DETERIORO .....  | 17   |
| 2.3.1    Introducción .....  | 17   |
| 2.3.2    Factores de influencia en el comportamiento del pavimento ..... | 19   |
| 2.3.3    Evaluación de condición del pavimento .....                     | 20   |
| CAPÍTULO 3. MACHINE LEARNING .....                                       | 28   |



|  |  |           |
|--|--|-----------|
| 3.1  | IA v/s ML v/s DL .....   | 28        |
| 3.2  | Programación con ML v/s programación tradicional.....                  | 29        |
| 3.3  | Procedimiento de desarrollo de modelos de predicción mediante ML ..... | 29        |
| 3.4  | Aprendizaje .....  | 31        |
| 3.4.1  | Entrenamiento, validación y testeo .....                               | 32        |
| 3.5  | Herramientas de Machine Learning y Deep Learning .....                 | 32        |
| 3.5.1  | Regresión .....  | 32        |
| 3.5.2  | Support Vector Machine .....   | 34        |
| 3.5.3  | Decision Tree & Random Forest .....                                    | 35        |
| 3.5.4  | Naïve Bayes .....  | 38        |
| 3.5.5  | K – Nearest Neighbors.....   | 39        |
| 3.5.6  | Programación Genética.....   | 40        |
| 3.5.7  | Artificial Neural Networks (ANN).....                                  | 41        |
| 3.5.8  | Herramientas de Deep Learning .....                                    | 44        |
| 3.6  | Metodología de modelamiento.....                                       | 45        |
| 3.6.1  | Enfoques de modelamiento.....  | 45        |
| 3.6.2  | Proyección de predicción.....  | 46        |
| 3.6.3  | Nivel de red v/s nivel de proyecto .....                               | 47        |
| 3.6.4  | Metodología de entrenamiento .....                                     | 48        |
| 3.6.5  | Optimización de modelos .....  | 48        |
| 3.6.6  | Criterios de Evaluación.....   | 50        |
| 3.6.7  | Marco de comparación de modelos .....                                  | 53        |
| 3.6.8  | Análisis de sensibilidad: .....  | 54        |
| <b>CAPÍTULO 4. ANÁLISIS ESTADÍSTICO Y COMPARACIÓN DE HERRAMIENTAS DE MACHINE LEARNING APLICADO A MODELOS DE COMPORTAMIENTO .....</b> |  | <b>56</b> |
| 4.1  | Metodología de búsqueda.....   | 56        |
| 4.2  | Resultados .....   | 57        |
| 4.2.1  | Base de datos.....   | 57        |
| 4.2.2  | Variables de entrada.....  | 65        |
| 4.2.3  | Metodología de modelamiento .....                                      | 67        |





|   |  |     |
|---|--|-----|
| 4.2.4   | VARIABLES DE PREDICCIÓN.....   | 71  |
| 4.2.5   | HERRAMIENTAS DE MACHINE LEARNING.....  | 81  |
| 4.2.6   | MANTENIMIENTO Y REHABILITACIÓN.....  | 91  |
| CAPÍTULO 5. ÁRBOL DE DECISIÓN Y VISUAL BASIC..... |  | 92  |
| 5.1   | Árbol de decisión.....   | 92  |
| 5.1.1   | Organización.....  | 92  |
| 5.2   | Visual Basic.....  | 94  |
| CAPÍTULO 6. CONCLUSIONES Y RECOMENDACIONES.....   |  | 97  |
| 6.1   | Conclusiones.....  | 97  |
| 6.1.1   | Conclusión General.....  | 97  |
| 6.1.2   | Conclusiones específicas.....  | 97  |
| 6.2   | Recomendaciones.....   | 99  |
| 6.3   | Vacios dentro de la investigación:.....  | 100 |
| REFERENCIAS.....                                  |  | 101 |
| ANEXOS.....                                       |  | 111 |
| ANEXO A.  | Representación de estudios de Bibliografía.....                                      | 111 |
| ANEXO B.  | Conjunto de variables de entrada en función de la variable de predicción.....        | 117 |
| ANEXO C.  | División de base de datos en sub-conjunto de entrenamiento, validación y prueba..... | 122 |
| ANEXO D.  | Herramienta de ML para cada variable de predicción.....                              | 123 |
| ANEXO E.  | Comparación de modelos.....  | 127 |
| ANEXO F.  | Árbol de decisión.....   | 131 |
| ANEXO G.  | Visual Basic.....  | 134 |





## ÍNDICE DE FIGURAS

|  |     |
|--|-----|
| Figura 1: Curva de deterioro del pavimento en función del tiempo. (García, 2017) .....   | 4   |
| Figura 2: Estructura de pavimento asfáltico (García, 2017) .....   | 15  |
| Figura 3: Condiciones que influyen el comportamiento del pavimento. (Tighe et al., 2007) .....   | 19  |
| Figura 4: Escala estándar de PCI. (Younos et al., 2020) .....  | 25  |
| Figura 5: Comparación programación tradicional y programación con ML. ....   | 29  |
| Figura 6: Procedimiento de construcción de modelo de deterioro con herramienta de ML, basado en (S. Dong et al., 2019).....  | 30  |
| Figura 7: Ejemplo de hiper-planos de separación generados con SVM en problema lineal; donde la línea central y maciza representa el hiper-plano óptimo. ....   | 34  |
| Figura 8: Diferencia entre SVC (izquierda) y SVR (derecha). (X. Wang et al., 2020) .....   | 35  |
| Figura 9: Procedimiento general en modelamiento con Naïve Bayes. (Parvini, 2002) .....   | 38  |
| Figura 10: Arquitectura general de una ANN con Back-propagation y Feed-Forward. (Dimitrovic et al., 2018). ....  | 42  |
| Figura 11: Diagrama de enfoques de modelamiento. ....  | 46  |
| Figura 12: Diagrama de proyección de predicción considerada en la clasificación de los documentos en estudio.....  | 46  |
| Figura 13: Representación del complemento de proyectos a nivel de red y proyecto. (Hernan Solminihac et al., 2018) .....   | 47  |
| Figura 14: Recurrencia de proyección de predicción en documentos .....   | 69  |
| Figura 15: Simbología de colores de representación estadística (porcentual) dentro del DT.....   | 92  |
| Figura 16: Simbología de herramientas de ML necesaria para comprender árbol de decisión. ....  | 93  |
| Figura 17: Estructura principal del árbol. ....  | 93  |
| Figura 18: Hoja principal del Excel, necesaria para dar inicio a la programación en Visual Basic. ....   | 94  |
| Figura 19: Formato típico de User Form, con definición de c/botón.....   | 95  |
| Figura 20: Glosario de tipos de pavimentos dentro del software.....  | 95  |
| Figura 21: Ejemplo de resultado del modelo escogiendo lo más usado en cada UF. ....  | 96  |
| Figura 22: Sección 1.1 del árbol de decisión, correspondiente a los pavimentos flexibles del modelamiento mixto. ....  | 131 |
| Figura 23: Sección 1.2 del árbol de decisión, correspondiente a los pavimentos rígidos, caminos no pavimentados y pavimentos con mejora del modelamiento mixto. ....   | 131 |
| Figura 24: Sección 2 del árbol de decisión, correspondiente al modelamiento en serie de tiempo.....  | 132 |
| Figura 25: Sección 3.1.1 del árbol de decisión, correspondiente al IRI, Agrietamiento, Ahuellamiento, Agrietamiento por reflexión, Pérdida de áridos, T° superficial y permeabilidad de pavimentos flexibles del modelamiento multi-variable. .... | 132 |



---

|  |     |
|--|-----|
| Figura 26: Sección 3.1.1 del árbol de decisión, correspondiente al Esfuerzo, ESAL, Condición superficial, Vida útil restante, PCI, Desempeño, Condición del pavimento y BCCI de pavimentos flexibles del modelamiento multi-variable. .... | 132 |
| Figura 27: Sección 3.2 del árbol de decisión, correspondiente a los pavimentos rígidos y pavimentos con mejora del modelamiento multi-variable. ....   | 133 |
| Figura 28: Glosario de variable de predicción para pavimentos flexibles, con enfoque de modelamiento mixto. ....   | 134 |
| Figura 29: Glosario de variable de predicción para pavimentos rígidos, con enfoque de modelamiento mixto. ....   | 134 |
| Figura 30: Glosario de variable de predicción para pavimentos con mejora, con enfoque de modelamiento mixto. ....  | 135 |
| Figura 31: Glosario de variable de predicción para pavimentos flexibles, con enfoque de modelamiento en series de tiempo. ....   | 135 |
| Figura 32: Glosario de variable de predicción para pavimentos rígidos, con enfoque de modelamiento en series de tiempo. ....   | 136 |
| Figura 33: Glosario de variable de predicción para pavimentos flexibles, con enfoque de modelamiento multi-variable. ....  | 136 |
| Figura 34: Glosario de variable de predicción para pavimentos rígidos, con enfoque de modelamiento multi-variable. ....  | 137 |
| Figura 35: Glosario de variable de predicción para caminos no pavimentados, con enfoque de modelamiento multi-variable. ....   | 137 |
| Figura 36: Glosario de variable de predicción para pavimentos con mejora, con enfoque de modelamiento multi-variable. ....   | 138 |





## ÍNDICE DE GRÁFICOS



|  |    |
|--|----|
| Gráfico 1: Distribución de Red Vial Nacional según tipo de Capa de Rodadura - Dic, 2019.....   | 11 |
| Gráfico 2: Base de datos presentes en los documentos leídos y clasificados se Scopus. ....   | 57 |
| Gráfico 3: Bases de datos provenientes de Departamento de Transporte.....  | 59 |
| Gráfico 4: Datos recopilados y/o medidos.....  | 61 |
| Gráfico 5: División base de datos en sub-conjuntos de entrenamiento, validación y testeo, para las herramientas de ML. ....                        | 64 |
| Gráfico 6: Conjunto de variables de entrada requeridos según las variables de predicción, para cada tipo de pavimento.....                         | 66 |
| Gráfico 7: Enfoques de modelamiento según herramienta de ML .....  | 68 |
| Gráfico 8: Relación entre la herramientas de ML y la proyección de predicción .....  | 70 |
| Gráfico 9: Recurrencia de nivel de estudio para los distintos tipos de pavimento. ....   | 71 |
| Gráfico 10: Variables de predicción según tipos de pavimentos.....   | 72 |
| Gráfico 11: Herramientas de ML según modelos de deterioro y M&R. ....  | 81 |
| Gráfico 12: Herramientas de ML para cada variable de predicción, según tipo de pavimento. ....   | 88 |
| Gráfico 13: a) Total de capa(s) oculta(s) y el intervalo del total de neuronas correspondientes y b) total de variables en la capa de entrada..... | 89 |

## ÍNDICE DE TABLAS

|  |    |
|--|----|
| Tabla 1: Características de métodos empíricos y empíricos-mecanicistas disponibles para modelos de deterioro (Karballeezadeh et al., 2019).....  | 5  |
| Tabla 2: Experimentos generales (GPS) y específicos (SPS) de la base de datos LTTP. (Federal Highway Administration, 2017).....  | 7  |
| Tabla 3:Tabla comparativa de modelos deterministas y probabilísticos. (W. Wang et al., 2017) .....   | 18 |
| Tabla 4: Ventajas y desventajas de la regresión logística.....   | 33 |
| Tabla 5: Ventajas y desventajas de los modelos SVM. (Rebala et al., 2019a; Tabatabaee et al., 2013; Yan & Zhang, 2011).....  | 34 |
| Tabla 6: Comparación de modelos DT y RF, con sus respectivas ventajas y desventajas. (Fathi et al., 2019; H. Gong et al., 2018; Sylvester Inkoom et al., 2019; Marcelino et al., 2019; Rebala et al., 2019a) ..... | 37 |
| Tabla 7:Ventajas y desventajas de Naïve Bayes. (Sylvester Inkoom et al., 2019; Parvini, 2002; Rebala et al., 2019a).....   | 39 |
| Tabla 8: Ventajas y desventajas de KNN (Sylvester Inkoom et al., 2019; Rebala et al., 2019a).....  | 40 |
| Tabla 9: Ventajas y Desventajas de GP (Chang et al., 2008). ....   | 41 |
| Tabla 10: Ventajas y desventajas de las redes neuronales.(Bianchini & Bandini, 2010; Marcelino et al., 2019; Shafabakhsh et al., 2015; W. Wang et al., 2017).....  | 43 |





|   |     |
|---|-----|
| Tabla 11: Comparación de herramientas de DL, con sus ventajas y desventajas.(S. Choi & Do, 2019; Y. Dong et al., 2019; Hongren Gong et al., 2018; Tabatabaee et al., 2013)..... | 45  |
| Tabla 12: Matriz de confusión para problemas de clasificación binarios.....   | 52  |
| Tabla 13: Combinación de palabras claves en Scopus para obtener pesquisa completa. ....   | 56  |
| Tabla 14: Información clasificada de cada documento leído.....  | 56  |
| Tabla 15: Extracto de tabla en ANEXO A, con el fin de simplificar referencias en resumen de resultados.<br>.....  | 57  |
| Tabla 16: Documentos base de datos sintéticos con su fuente respectiva. ....  | 62  |
| Tabla 17: Documentos con base de datos compuesta y su fuente de obtención.....  | 63  |
| Tabla 18: Variables de entrada más utilizadas en modelos de deterioro, según categoría. ....  | 65  |
| Tabla 19: Número y porcentaje de estudios realizados con los enfoques de modelamiento, según tipo de<br>pavimento.....  | 67  |
| Tabla 20: Análisis estadístico de comparación de herramientas de ML según el coeficiente de correlación.<br>.....   | 90  |
| Tabla 21: Numero de referencia de estudios, con el título, autor, año y bibliografía respectiva.....  | 111 |
| Tabla 22: Conjunto de variable de entrada en función de la variable de predicción, para pavimento flexible.<br>.....  | 117 |
| Tabla 23: Conjunto de variable de entrada en función de la variable de predicción, para pavimento rígido.<br>.....  | 119 |
| Tabla 24: Conjunto de variable de entrada en función de la variable de predicción, para camino no<br>pavimentado.....   | 120 |
| Tabla 25: Conjunto de variable de entrada en función de la variable de predicción, para pavimento con<br>mejora. ....   | 121 |
| Tabla 26: Subconjuntos de base de datos para obtener algoritmos de modelación, según herramientas de<br>ML.....   | 122 |
| Tabla 27: Herramienta de ML para cada variable de predicción según tipo de pavimento.....   | 123 |
| Tabla 28: Documentos encontrados con comparación de modelos de ML. ....   | 127 |
| Tabla 29: Tabla comparativa de herramientas de ML con errores mayores y menores respectivamente..<br>.....  | 128 |




## LISTA DE ABREVIACIONES



| ABREVIACIÓN      | INGLÉS  | ESPAÑOL   |
|------------------|---|---|
| <b>ANN</b>       | Artificial Neural Network   | Red Neuronal Artificial   |
| <b>AASHO</b>     | American Association of State Highway Officials                                   | Asociación Estadounidense de Oficiales de Carreteras Estatales                                    |
| <b>AASHTO</b>    | American Association of State Highway and Transportation Officials                | Asociación Americana de Oficiales de Carreteras Estatales y Transportes.                          |
| <b>Adam</b>      | Adaptive Moment Estimation  | Estimación Del Momento Adaptativo   |
| <b>ADT</b>       | Annual Daily Traffic  | Volumen de tránsito diario  |
| <b>AI</b>        | Artificial Intelligence   | Inteligencia Artificial   |
| <b>ANFIS</b>     | Adaptive Neuro-Fuzzy Inference System   | Sistema Adaptativo de Interferencia Difusa  |
| <b>ANN</b>       | Artificial Neural Network   | Red Neuronal Artificial   |
| <b>ARAN</b>      | Automatic Road Analyzer   | Vehículo Analizador Automático  |
| <b>ASTM</b>      | American Society for Testing and Materials  | Sociedad Americana para Pruebas y Materiales  |
| <b>BCCI</b>      | Base Core Condition Index   | Índice de Condición de Base Core  |
| <b>CART</b>      | Classification and Regression Tree  | Árbol de Clasificación y Regresión  |
| <b>CMIS</b>      | Committee Machine Intelligent Systems   | Comité de Sistemas Inteligentes de Máquinas   |
| <b>DT</b>        | Decision Tree   | Árbol de decisión   |
| <b>DL</b>        | Deep Learning   | Aprendizaje Profundo  |
| <b>ELU</b>       | Exponential Linear Unit   | Unidad Lineal Exponencial   |
| <b>ESAL</b>      | Equivalent Single Axle Load   | Carga de un Eje Equivalente   |
| <b>FA</b>        | Firefly Algorithm   | Algoritmo de Luciérnagas  |
| <b>FAARFIELD</b> | Federal Aviation Administration Rigid and Flexible Iterative Elastic Layer Design | Diseño de capa Rígida y Flexible de interacción Elástica de la Administración Federal de Aviación |
| <b>FDOT</b>      | Florida Department of Transportation  | Departamento de Transporte de Florida   |
| <b>FNN</b>       | Fuzzy Neural Network  | Red Neuronal Difusa   |
| <b>FOA</b>       | Fruit Fly Optimization Algorithm  | Algoritmo de Optimización de la Mosca de la Fruta   |
| <b>FTA</b>       | Finnish Transport Agency  | Agencia de Transporte de Finlandia  |
| <b>FWD</b>       | Falling Weight Deflectometer  | Deflectómetro de Caída de Peso  |
| <b>GBM</b>       | Gradient Boosted Model  | Modelo Impulsado por Gradiente  |
| <b>GEP</b>       | Gene Expression Programming   | Programación de la Expresión Genética   |
| <b>GP</b>        | Genetic Programming   | Programación Genética   |



|                |  |  |
|----------------|--|--|
| <b>GPR</b>     | Ground Penetrating Radar                               | Georradar  |
| <b>GPS</b>     | General Pavement Study                                 | Estudio General de Pavimentos                                |
| <b>GRA</b>     | Grey Relation Analysis                                 | Análisis de Relaciones Grises                                |
| <b>HYBRID</b>  | Hybrid modeling  | Modelamiento híbrido   |
| <b>IA</b>      | Artificial Intelligence                                | Inteligencia Artificial                                      |
| <b>ICA</b>     | Imperialist Competitive Algorithm                      | Algoritmo de Competencia Imperialista                        |
| <b>IRI</b>     | International Roughness Index                          | Índice de Rugosidad Internacional                            |
| <b>JPCP</b>    | Jointed Plain Concrete Pavement                        | Pavimento de Hormigón Liso Articulado                        |
| <b>KDOT</b>    | Kansas Department of Transportation                    | Departamento de Transporte de Kansas                         |
| <b>KNN</b>     | K-nearest neighbors                                    | K – Vecinos más Cercanos                                     |
| <b>KRISS</b>   | Korean Research Institute of Standards Science         | Instituto de Investigación de Estándares y Ciencia de Corea  |
| <b>LaDOTD</b>  | Louisiana Department of Transportation and Development | Departamento de Transporte y Desarrollo de Luisiana          |
| <b>LM</b>      | Levenberg-Marquardt                                    | -  |
| <b>LSTM</b>    | Long Short-Term Memory                                 | Long Short-Term Memory                                       |
| <b>LTPP</b>    | Long-Term Pavement Performance                         | Desempeño del pavimento a largo plazo                        |
| <b>M&amp;R</b> | Maintenance & Rehabilitation                           | Mantenimiento y Rehabilitación                               |
| <b>MAC</b>     | Hot Mix Asphalt  | Mezcla Asfáltica en Caliente                                 |
| <b>MAE</b>     | Mean Absolute Error                                    | Error Absoluto Medio   |
| <b>MARS</b>    | Multivariate adaptive regression splines               | Splines de Regresión Adaptativa Multivariante                |
| <b>MAPE</b>    | Mean Absolute Percentage Error                         | Error del Porcentaje Absoluto Medio                          |
| <b>MEPDG</b>   | Mechanistic-Empirical Pavement Design Guide            | Guía de Diseño de Pavimento Empírico-mecanicista             |
| <b>ML</b>      | Machine Learning                                       | Aprendizaje Automático                                       |
| <b>MLR</b>     | Multivariable Linear Regression                        | Regresión Lineal Multi-variable                              |
| <b>MOP</b>     | Ministry of Public Works                               | Ministerio de Obras Públicas                                 |
| <b>MSE</b>     | Mean Squared Error                                     | Error Cuadrático Medio                                       |
| <b>NCHRP</b>   | National Cooperative Highway Research Program          | Programa Nacional de Investigación Cooperativa de Carreteras |
| <b>ODOT</b>    | Oregon State Department of Transportation              | Departamento de Transporte del Estado de Oregón              |
| <b>PCC</b>     | Portland Cement Concrete                               | Concreto de Cemento Portland                                 |
| <b>PCI</b>     | Pavement Condition Index                               | Índice de Condición del Pavimento                            |
| <b>PCR</b>     | Pavement Condition Rating                              | Clasificación de Condición del Pavimento                     |
| <b>PCS</b>     | Pavement Condition Survey                              | Encuesta del Estado del Pavimento                            |



|              |   |   |
|--------------|---|---|
| <b>PPEI</b>  | Pavement Performance Evaluation Index   | Índice de Evaluación de Desempeño del Pavimento |
| <b>PSI</b>   | Pavement Serviceability Index           | Índice de Serviabilidad del Pavimento           |
| <b>PSO</b>   | Particle Swarm Optimization             | Optimización de Enjambre de Partículas          |
| <b>RAP</b>   | Reclaimed Asphalt Pavement              | Pavimento Asfáltico Recuperado                  |
| <b>RBF</b>   | Radial Basis Function                   | Función de Base Radial                          |
| <b>RCS</b>   | Road Condition Survey                   | Encuesta del Estado de la Carretera             |
| <b>RF</b>    | Random Forest                           | Bosque Aleatorio                                |
| <b>RMSE</b>  | Root Mean Squared Error                 | Raíz del Error Cuadrático Medio                 |
| <b>RNN</b>   | Recurrent Neural Network                | Red Neuronal Recurrente                         |
| <b>RSL</b>   | Remaining Service Life                  | Vida Útil Restante                              |
| <b>RWD</b>   | Rolling Wheel Deflectometer             | Deflectómetro de rueda rodante                  |
| <b>SCG</b>   | Scaled Conjugate Gradient               | Gradiente Escalado Conjugado                    |
| <b>SCI</b>   | Structural Condition Index              | Índice de Condición Estructural                 |
| <b>SCR</b>   | Surface Condition Rating                | Índice de Condición Superficial                 |
| <b>SDI</b>   | Structural Distress Index               | Índice de Deterioro Superficial                 |
| <b>SFC</b>   | Sideway Force Coefficient               | Coefficiente de Fuerza Lateral                  |
| <b>SGP</b>   | Pavement Management System              | Sistema de Gestión de Pavimentos                |
| <b>SIF</b>   | Stress Intensity Factor                 | Factor de Intensidad de Tensión                 |
| <b>SPS</b>   | Specific Pavement Study                 | Estudio Específico de Pavimentos                |
| <b>SRI</b>   | Skid-Resistance Index                   | Índice de Resistencia al Deslizamiento          |
| <b>SSI</b>   | Structure Strength Index                | Índice de Resistencia de la Estructura          |
| <b>ST</b>    | Structural Number                       | Número Estructural                              |
| <b>SVC</b>   | Support Vector Classification           | Clasificación de Vectores de Soporte            |
| <b>SVM</b>   | Support Vector Machine                  | Máquina de Vectores de Soporte                  |
| <b>SVR</b>   | Support Vector Regression               | Regresión de Vectores de Soporte                |
| <b>TMAPA</b> | Annual Weighted Average Air Temperature | Temperatura Media Anual Ponderada del Aire      |





## CAPÍTULO 1. INTRODUCCIÓN

El desarrollo económico y social de un país depende del buen manejo de la inversión en la infraestructura vial, para impulsar al crecimiento y que permita la circulación nacional e internacional de mercancías y personas bajo estándares de seguridad y confort. En Chile, al año 2013 el patrimonio vial se estimaba en US\$26.783 (valor del dólar al 31 de Dic del 2013) millones de los cuales el 60.04% correspondía a caminos pavimentados (Muñoz, 2016). El encargado de planificar, regular e implementar las políticas de infraestructura es el Ministerio de Obras Públicas (MOP). En este contexto y ante el inevitable deterioro de los pavimentos, resulta indispensable contar con sistemas de gestión de pavimentos que permitan una asignación eficiente de recursos para la construcción, operación y conservación de estos. Para tomar dichas decisiones los expertos se apoyan de modelos de deterioros capaces de predecir la condición de los pavimentos, en el corto o largo plazo, tomando en cuenta los efectos de alternativas de mantención (Hernán Solminihaç, 2018).

En el pasado se han creado diversos modelos de deterioro mediante técnicas clásicas como las regresiones y enfoques probabilísticos como cadenas de Markov. Sin embargo, estos modelos presentan algunas limitaciones como baja capacidad de precisión y dificultad de calibrar a condiciones distintas de las originales (Hernán Solminihaç, 2018). Por esto, es necesario explorar otras herramientas con mejor capacidad de precisión y generalización.

Actualmente, han surgido con fuerza los conceptos de Machine Learning (ML) en el ámbito de la ingeniería de pavimentos. ML son herramientas que desarrollan modelos y algoritmos que permiten integrar múltiples variables y analizar relaciones que no son evidentes. Abambres & Ferreira, (2017), y Ceylan et al., (2014), han recopilado múltiples aplicaciones de ML en pavimentos como: diseño y modelación de materiales, clasificación y análisis de imágenes de deterioro, evaluación estructural, selección de estrategias de mantención en sistemas de gestión, entre otros.

Chile se ve impulsado al desarrollo de tecnologías que son claves para el desarrollo social, la inteligencia artificial y el manejo de datos forman parte del nuevo escenario hacia el que se mueve el mundo. Esta es la razón del aumento en investigaciones, las distintas herramientas de ML han sido aplicadas en modelos de deterioro obteniendo en general buenos resultados. Son tantos los modelos desarrollados que nacen diversas opciones de modelamiento: cuál herramienta de ML usar, qué técnicas de aprendizaje hay disponibles, cómo debe ser el manejo de los datos, hay factibilidad de aplicación, entre otras.



El presente trabajo realiza una revisión bibliográfica actualizada de aplicaciones de ML en modelos de comportamiento de pavimentos, con el fin de proporcionar un marco teórico con los beneficios y limitaciones de estas técnicas para futuras investigaciones en el área. Además, proporciona una herramienta de visualización que ayuda a determinar de manera versátil la técnica de ML más apropiada para aplicar modelos de deterioro teniendo en consideración resultados, ventajas y desventajas, variables de predicción, tipo de pavimento, proyección de predicción, nivel de estudio y forma de modelamiento.

## 1.1 Objetivos Generales



Desarrollar herramientas de visualización de aplicaciones de técnicas de ML a modelos de comportamiento de pavimentos.

## 1.2 Objetivos Específicos

- Desarrollar análisis crítico de aplicaciones de herramientas de ML en el desarrollo de modelos de comportamiento de pavimentos.
- Proponer un árbol de decisión que modele las herramientas de ML aplicadas u oportunidades en el desarrollo de modelos de comportamiento de pavimento en base a nivel de estudio, tipo de pavimento, proyección de predicción, variables de entrada y salida más usadas, resultados y conclusiones.
- Programar el árbol de decisión desarrollado mediante Visual Basic.

## 1.3 Alcance del estudio

- El árbol de decisión es una herramienta de ML basada en decisiones que no se actualiza automáticamente, por lo que todo documento nuevo debe ser incluido manualmente.
- El resultado del software creado con Visual Basic permite obtener todas las técnicas de ML aplicadas a condiciones en específico, por lo tanto, la herramienta más eficiente será obtenida mediante prueba y error.



## CAPÍTULO 2. MARCO TEÓRICO

### 2.1 GESTIÓN DE INFRAESTRUCTURA VIAL

La gestión de infraestructura vial está encargada de administrar todos los elementos que concluyen un camino a través de un conjunto de actividades que permitan el funcionamiento armónico de la infraestructura. Las redes viales representan una importante inversión en infraestructura, lo que determina el bienestar, crecimiento y desarrollo de cualquier país. La carga de tránsito, las condiciones climáticas, las propiedades de los materiales de construcción, calidad de construcción y estrategia de mantenimiento y rehabilitación previos son unos de los aspectos claves del diseño y desempeño del pavimento. (Younos et al., 2020). Las actividades deben ser programadas con planificación, diseño, construcción, mantenimiento, evaluación e investigación de activos viales, la mayoría de los proyectos viales siguen la siguiente secuencia (Hernan Solminihac et al., 2018):

- Adquisición y recopilación de datos: datos detallados en los que se incluyan solicitudes, datos estructurales, consistencia en la toma de datos, edad del pavimento, intervenciones, etc. y en lo posible datos históricos.
- Planificación y programación de mantención, rehabilitación y/o reconstrucción.
- Diseño de detalle de proyectos individuales.
- Seguimiento periódico de pavimentos existentes: evaluación periódica de patrimonio vial, lo que permite validación y calibración de modelos de deterioro.

#### 2.1.1 Sistema de gestión de pavimentos

Los Sistemas de Gestión de Pavimentos (SGP) son conjuntos de herramientas analíticas desarrolladas para la ayuda de la toma de decisiones de redes de pavimentos. Son métodos que mantienen y/o mejoran la calidad de la red de caminos, utilizando los recursos disponibles de la forma más eficaz y eficiente posible. Los modelos de predicción son una parte principal dentro del SGP a nivel de red, puesto que predicen la condición futura, identifican necesidades de mantenimiento y rehabilitación, y estiman las condiciones luego de la aplicación de varias alternativas de tratamiento, generan un sistema de priorización de intervenciones de mantenimiento y rehabilitación (M&R, Maintenance & Rehabilitation), entre otros. Es por esto que es importante contar con más y mejores datos para que el SGP sea confiable, preciso y completo. (Kargah-Ostadi, 2014; Marcelino et al., 2020).

La curva de deterioro en el tiempo permite determinar el momento óptimo de mantenimiento (mantenimiento preventivo) para hacer que el pavimento perdure el mayor tiempo posible y a un menor costo de inversión, denominado mantenimiento preventivo. Luego, el pavimento comienza a deteriorarse y los costos de reparación y mantenimiento aumentan, llegando a un punto en el que el pavimento se deteriora tanto que debe ser reconstruido para volver a dar un buen servicio, ver FIGURA 1. (García, 2017)

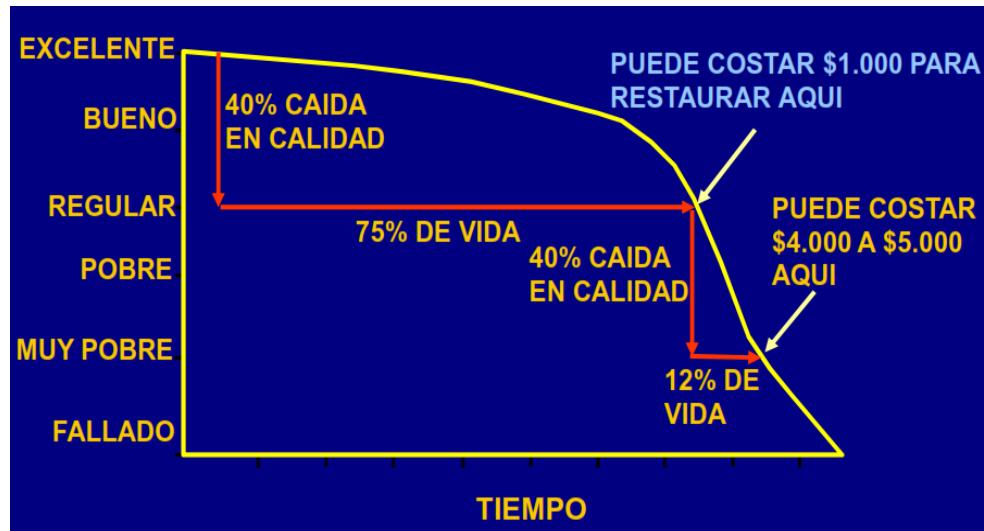




Figura 1: Curva de deterioro del pavimento en función del tiempo. (García, 2017)

El modelo de comportamiento del pavimento es fundamental para evaluar la eficacia de las estrategias de M&R, como se muestra en la FIGURA 1, esto podría minimizar el costo de mantenimiento si se conserva el pavimento en un nivel aceptable de servicio (Lucey et al., 2019). Sin embargo, debido al gran número de variables y su compleja interacción, el enfoque estadístico simple (lineal) no es suficiente para desarrollar modelos de desempeño de pavimentos. Se deben probar múltiples arreglos para obtener la curva de comportamiento, mediante un modelo de regresión no lineal. Las herramientas de ML parecen ser una buena alternativa para desarrollar modelos más simples y precisos (Kargah-Ostadi & Stoffels, 2015).

### 2.1.2 Gestión Actual

Actualmente se cuenta con diferentes modelos para predecir el comportamiento de pavimentos; están los modelos deterministas que son los que cuentan con conjunto de variables independientes y las relacionan con un indicador, estos modelos se sub-dividen en mecanicistas, empíricos y empíricos-mecanicistas. Su principal diferencia es que los mecanicistas se basan en principios físicos, en cambio, los empíricos resultan de interpretaciones estadísticas. Ambos enfoques se pueden desarrollar con enfoques Bayesianos, regresiones, modelos estocásticos, redes neuronales, etc. (Marcelino et al., 2020)





Para llegar al diseño y mantenimiento óptimo se requiere de buena precisión en la predicción del deterioro; lo cual se ve influenciado por incertidumbres en las cargas de tránsito, las condiciones ambientales, propiedades mecánicas de los materiales, desempeño estructural y procesos constructivos. Es por esto que no se puede garantizar satisfacción absoluta y se debe complementar el estudio con criterios de estadística y probabilidades (Rodríguez Moreno et al., 2013).

Con el tiempo se ha producido una evolución en el diseño, pasando de empírico a empírico-mecanicista, ya que integra aspectos estructurales del pavimento y propiedades de los materiales (ver TABLA 1).

Tabla 1: Características de métodos empíricos y empíricos-mecanicistas disponibles para modelos de deterioro (Karballaezadeh et al., 2019)

| MÉTODO                      |           | CARACTERÍSTICAS   |
|-----------------------------|-----------|---|
| <b>Empírico</b>             | AASHTO 93 | <ul style="list-style-type: none"><li>• Pruebas empíricas en pavimentos rígidos y flexibles.</li><li>• Incorpora conceptos de confiabilidad, variabilidad y rehabilitación.</li><li>• Introduce el concepto de serviciabilidad (PSI).</li><li>• Pavimentos se someten a niveles de tránsito bajo, medio y alto.</li></ul>   |
| <b>Empírico-Mecanicista</b> | AASHTO 98 | <ul style="list-style-type: none"><li>• Diseño empírico-mecanicista que añade modificaciones a las ecuaciones de diseño de la AASHTO 93.</li><li>• Integra los conceptos de tensiones críticas, variables de temperatura y condiciones estructurales.</li><li>• Incluye verificación por escalonamiento y agrietamiento de esquina en pavimentos rígidos.</li></ul> |
|                             | MEPDG     | <ul style="list-style-type: none"><li>• Diseño empírico mecanicista enfocado en la predicción de deterioros del pavimento, generando diseños más precisos.</li></ul>  |

En Chile se diseñan los pavimentos asfálticos sólo con métodos empíricos, observando el comportamiento de la estructura cuando es sometida a cargas de tránsito y ciertas condiciones ambientales. El MOP ajusta el método de la *American Association of State Highway and Transportation Officials* (AASHTO - Asociación Americana de Oficiales de Carreteras Estatales y Transportes, en español) a las condiciones de Chile, introduciendo al diseño el concepto de Temperatura Media Anual Ponderada del Aire (TMAPA) para determinar el número estructural mínimo que deben tener las capas asfálticas, tabulando y graficando los resultados para poder calcular el número estructural mínimo de capas asfálticas. En los pavimentos rígidos se utiliza el diseño empírico-mecanicista de la *Mechanistic-Empirical Pavement Design Guide* (MEPDG - Guía de Diseño de Pavimentos Empírico-Mecanicista, en español) ajustado a la realidad de Chile, considerando variables de clima, tránsito y condiciones estructurales.



HDM-4 es una herramienta de gestión y desarrollo dedicada a apoyar la toma de decisiones relacionada con la gestión de la conservación y rehabilitación de pavimentos de redes viales. Este instrumento fue desarrollado por el Banco Mundial para ayudar a los países en vías de desarrollo proporcionando la metodología más avanzada usada actualmente para poder predecir la evolución del deterioro de pavimentos a nivel de red en función a los diversos componentes que se involucran. Es una herramienta versátil en su aplicación, donde el usuario debe definir el perfil de aplicación, instancia en la que le interesa trabajar y acomodar los datos para su correcto uso.


### 2.1.3 Inventario

El núcleo de cualquier sistema de gestión es la precisión y relevancia de los datos, ya que todo resultado o salida de un modelo estará directamente relacionado con la calidad de la entrada, es por esto que la base de datos debe ser robusta y completa. Varios modelos de los documentos leídos derivaron de la base de datos *Long-Term Pavement Performance* (LTPP - Comportamiento del Pavimento a Largo Plazo, en español), otros basados en mediciones directas, recolecciones de datos en laboratorios y otros en base de datos de agencias locales. También hay modelos que componen su base de datos de dos fuentes distintas cuando sólo una no es suficiente. A continuación, se describen las bases de datos usadas en los documentos leídos.

#### 2.1.3.1 LTPP

LTPP es una base de datos pública establecida en Estados Unidos que dispone de información sobre las características de pavimentos y su evolución dentro de una red en servicio. Es una de las bases de datos más completa y confiable de datos de desempeño del pavimento (Abdelaziz et al., 2020). Posee información de más de 2.500 secciones de pavimento de prueba en EE.UU y Canadá, con datos de materiales, comportamiento, tránsito, clima, edad del pavimento e intervenciones de M&R. Además, tiene una herramienta en línea versátil que permite acceder a la base de datos, descargarla y usarla, *LTPP-InfoPave* es la versión más reciente.



LTPP contiene dos secciones principales: *General Pavement Study* (GPS - Estudio General de Pavimento, en español) y *Specific Pavement Study* (SPS - Estudio de Pavimento Específico, en español) de aproximadamente 900 y 1600 secciones, respectivamente. Ambas secciones se complementan SPS ayudan a desarrollar una buena comprensión de efectos que no están incluidos en GPS; GPS es útil para hacer estudios a nivel de red y SPS, estudios a nivel de proyecto (Lucey et al., 2019; Marcelino et al., 2019, 2020).



- **GPS:** Utiliza secciones de pavimentos en servicio para ver el desempeño general por tipo de pavimento durante su vida útil. Permite que se implemente inmediatamente; sin embargo, en todas las secciones no se sabe la edad del pavimento y si ha tenido algún mantenimiento y/o rehabilitación. GPS se agrupan según tipo de pavimento y tratamientos superficiales: pavimento flexible (GPS-1 y -2), pavimento rígido (GPS-1, -4 y -5) y recubrimiento (GPS-6 y -7), ver TABLA 2. (Federal Highway Administration, 2017)
- **SPS:** Utiliza secciones construidas especialmente para investigar la influencia del desempeño de características en específico: drenaje, espesor de la capa, tratamientos de rehabilitación o mantenimiento, entre otros. (Federal Highway Administration, 2017)

Tabla 2: Experimentos generales (GPS) y específicos (SPS) de la base de datos LTPP. (Federal Highway Administration, 2017)

| Experimentos de GPS |   | Experimentos de SPS |   |
|---------------------|---|---------------------|---|
| GPS-1               | Pavimento de hormigón asfáltico sobre base granular   | SPS-1               | Estudio de factores estructurales para pavimentos flexibles   |
| GPS-2               | Pavimento de hormigón asfáltico sobre base unida  | SPS-2               | Estudio de factores estructurales para pavimentos rígidos   |
| GPS-3               | Pavimento de hormigón articulado  | SPS-3               | Efectividad de mantenimiento preventivo en pavimentos flexibles   |
| GPS-4               | Pavimento de hormigón armado articulado   | SPS-4               | Efectividad de mantenimiento preventivo en pavimentos rígidos   |
| GPS-5               | Pavimento de hormigón armado continuo   | SPS-5               | Rehabilitación de pavimentos de hormigón asfáltico  |
| GPS-6               | Recubrimiento de hormigón asfáltico sobre pavimento de hormigón asfáltico                                 | SPS-6               | Rehabilitación de pavimentos articulados de hormigón de cemento Portland  |
| GPS-7               | Recubrimiento de hormigón asfáltico sobre pavimento de hormigón   | SPS-7               | Recubrimiento de hormigón de cemento Portland adherido sobre pavimento de hormigón de cemento Portland                            |
| GPS-8               | Recubrimiento de hormigón de cemento Portland (reemplazado por SPS-7)                                     | SPS-8               | Estudio de efectos ambientales en ausencia de cargas pesadas  |
| GPS-9               | Recubrimiento de hormigón de cemento Portland no adherido sobre pavimento de hormigón de cemento Portland | SPS-9               | Validación de la especificación de asfalto y diseño de mezcla del programa de investigación estratégica de carreteras (Superpave) |
|                     |   | SPS-10              | Recubrimiento de mezcla asfáltica en caliente sobre pavimentos asfálticos (2014)  |



Abdelaziz et al., (2020), establece dos limitaciones de LTPP: no hay información concreta de las mediciones de rugosidad iniciales, ya que existían de antes, y que las mediciones de los indicadores y las fallas del pavimento no se realizaron al mismo tiempo, por lo que no se hace sencillo relacionarlas.

### 2.1.3.2 Departamento de Transporte

Son agencias gubernamentales encargadas de administrar el sistema de transporte de un país o estado. ADOT, KDOT, MDOT, ODOT, Ohio DOT son departamento de transporte de distintos estados de EE.UU. preocupados de desarrollar un sistema de transporte moderno, confiable, innovador y eficiente en los estados de Arizona, Kansas, Maine, Oregón y Ohio, respectivamente.

#### **ConnDOT**



El *Connecticut Department of Transportation* (ConnDOT - Departamento de Transporte de Connecticut, en español) es un organismo asesorado por el Instituto de transporte de la Universidad de Connecticut para administrar carreteras, sistemas de transporte público, ferroviarios, etc. En la actualidad se inspeccionan 7.438 *millas direccionales* cada año, lo que representa el 100% del sistema interestatal (primario y secundario) de la red de carreteras de Connecticut. (Department of Transportation, 2020)

#### **FDOT**

El *Florida Department of Transportation* (FDOT - Departamento de Transporte de Florida, en español), creado en 2017, mantiene los registros de inventario de sus segmentos de pavimento anualmente utilizando información de la base de datos del *Pavement Condition Survey* (PCS - Encuesta sobre el Estado del Pavimento, en español). Contiene la *Pavement Condition Rating* (PCR - Clasificación de Condición del Pavimento, en español) que combina tres deterioros principales del pavimento: agrietamiento, conducción y baches; cada uno clasificado de 0 a 10, donde 0 indica mala condición y 10 indica condición excelente. (FDOT, 2019; Sylvester Inkoom et al., 2019)

#### **LaDOTD**

El *Louisiana Department of Transportation and Development* (LaDOTD - Departamento de Transporte y Desarrollo de Luisiana, en español) es la agencia encargada del sistema de gestión, construcción y mantención de la red vial estatal y ferroviaria. Tiene un tecnología de evaluación automática utilizando un deflectómetro de rueda rodante (RWD - Rolling Wheel Deflectometer), el que obtiene la deflexión del camino simulando un vehículo que opera hasta 80 [km/h]. Las deformaciones funcionales se evalúan en carreteras cada dos años con el *Automatic Road Analyzer* (ARAN - Vehículo Analizador Automático, en español), almacenadas en la base de datos en una escala del 0 al 100. LaDOTD usa una matriz de decisión que depende de los índices de daño superficial y la clase funcional de la carretera. (Elbagalati et al., 2018; LaDOTD, 2020)



### 2.1.3.3 Recopilación de datos, evaluación in situ

Algunos documentos generan su propia base de datos, haciendo evaluación de secciones de pavimento y recopilando datos propios del país en estudio, esto implica mucho tiempo de dedicación o la restricción de hacer predicciones a corto plazo. Jalal et al., (2017), identifican y evalúan deterioros por tres años consecutivos en pavimentos rígidos, asfálticos y de concreto asfáltico ubicados en el Campus A&M de la Universidad de Texas.

Algunos extraen datos del *National Cooperative Highway Research Program* (NCHRP - Programa Nacional de Investigación Cooperativa de Carreteras, en español), que contiene datos de entrada para la calibración y validación de modelos de agrietamiento por fatiga en pavimentos flexibles y tratados. Estos datos son los mismos que se usan para calibrar las “funciones de transferencia” de MEPDG. (Hongren Gong, Sun, Hu, et al., 2019; Hongren Gong, Sun, & Huang, 2019)



En Corea se usan equipos automáticos que determinan anualmente las condiciones de 2.300 [km] de pavimentos, lo que corresponde al 20% del total de carreteras nacionales. El *Korean Research Institute of Standards Science* (KRISS - Instituto de Investigación de Estándares y Ciencia de Corea, en español) ha desarrollado tecnologías de estándares de medición, significando una mejora en la calidad de los productos industriales y una base de datos robusta para la red de pavimentos coreanos (Republic of Korea, 2017). Los instrumentos miden principalmente el agrietamiento, ahuellamiento e IRI, además de obtener un video del camino que recorre. La base de datos contiene datos de 11 años (desde 2007 a 2017). (S. Choi & Do, 2019)

### 2.1.3.4 Datos Sintéticos

Varios usan softwares para generar su propia base de datos, denominados “Datos Sintéticos”. Attoh-Okine (1994) generan datos de rugosidad con el Software RODEMAN, sub-modelo del HDM-III (Highway Development & Management), para predecir el International Roughness Index (IRI – Índice de Rugosidad Internacional, en español) en el tiempo en pavimentos flexibles.

### 2.1.3.5 Base de datos compuesta

Algunos documentos mezclan bases de dato ya que puede no ser suficiente (Marcelino et al., 2020). En algunos casos se quiere entrenar el modelo con una base de datos y luego validarla con datos reales (Whiteley-Lagace et al., 2011) o, también, se quiere estudiar un problema tan específico que no basta con la información disponible (Hossain et al., 2019, 2020).



### **Transfer Learning:**

*Transfer Learning* (Aprendizaje por transferencia) es un tipo de aprendizaje que puede mejorar la predicción cuando la base de datos de entrenamiento no es suficiente. Proporciona un sistema que es entrenado a partir de datos previos, para luego relacionarlo con los datos de interés. Existe un algoritmo llamado “TrAdaBoost”, complemento fundamental para el análisis por transferencia en problemas de clasificación, el cual establece que los dominios de origen y destino tienen el mismo conjunto de características y etiqueta, aunque la distribución de datos sea diferente y, mediante un proceso iterativo, reduce el efecto de los datos de origen “negativos” y estimula los de origen “positivo”. (Marcelino et al., 2020)

#### 2.1.3.6 Inventario de pavimentos en Chile

Chile no cuenta con una base de datos robusta, aun cuando el Ministerio de Obras Públicas (MOP) debe hacer un informe cada dos años de la situación actual de la red vial pública, no es una información detallada. Dentro de la información se cuenta con la capa de rodadura segmentada según región, pero no su condición actual, ni la especificación de algún tipo de estrategia M&R realizada.

La inexistencia de datos históricos, la frecuencia extensa de recopilación, la mala calidad de datos (faltantes, inconsistentes, valores fuera del rango esperado, etc) y la interacción de estos (toma de datos con distintos equipos y formatos de recopilación), son las principales razones que contribuyen a una base de datos incompletas y poco fiables. Por lo tanto, es de suma importancia preparar los datos antes de usarlos para el modelado (eliminar datos inconsistentes, vacíos, redundantes y duplicados), lo que conlleva a una base de datos tan pequeñas que no sirve para modelar la condición futura del pavimento.

El GRÁFICO 1 presenta la distribución de Red vial a diciembre del año 2019 publicado por el MOP, hasta la fecha la mayoría era de caminos no pavimentados y pavimentos flexibles.







Gráfico 1: Distribución de Red Vial Nacional según tipo de Capa de Rodadura - Dic, 2019.  
Fuente: <http://www.vialidad.cl/areasdevialidad/gestionvial/Documents/RedVialNacional2019.pdf>

Contar con más y mejores datos es una parte esencial de cualquier SGP que pueda definirse como confiable, preciso y completo. Marcelino et al., (2020) propone el método Transfer Learning (Transferencia de Aprendizaje) para dar solución a la insuficiencia de datos, en el que se usa una base de datos similar y más completa para entrenar el modelo, transfiriendo aprendizaje de una base de datos a otra, y finalmente usa la base de datos original para validar el modelo.

Para obtener los algoritmos de los modelos de ML, la base de datos se divide en subconjunto de entrenamiento, validación y prueba; esto permite tener una etapa de aprendizaje del modelo mediante los datos de entrenamiento y validación, y luego una etapa de verificación, la cual se desarrolla con los datos de prueba para evitar sub-estimación o sobreestimación. En el caso de las herramientas de *Deep Learning* (DL – aprendizaje profundo en español), el proceso de verificación se desarrolla con el fin de disminuir el error de entrenamiento sin aumentar errores en la generalización. “*Early Stopping*” es un método de aprendizaje en el cual se obtiene el modelo final a partir de un proceso iterativo, en el que se minimiza el error en el subconjunto de entrenamiento hasta que el error en el subconjunto de validación comienza a aumentar, con el fin de mejorar la generalización del modelo final.

#### 2.1.4 Pre-procesamiento de datos

El pre-procesamiento de datos es un análisis exploratorio de la base de datos donde se identifican valores inusuales, extremos, incompletos, discontinuidades, entre otros para asegurar una base de datos robusta y completa que sea adecuada para generar el modelo. Es uno de los pasos más importantes, puesto que de esto depende que el modelo sea generalizable y entregue buenos resultados.



A continuación, se describen algunas técnicas de pre-procesamiento empleadas por algunos investigadores en la mayoría de los problemas de ML:



**Eliminación de datos atípicos:** Consiste en eliminar datos que no correspondan a la lógica dentro de la base de datos. Kargah-Ostadi & Stoffels, (2015), eliminan las mediciones de IRI que fueran menor a su lectura anterior puesto que no se tenía certeza de haber realizado algún tratamiento de M&R. Jalal et al., (2017) eliminan los datos con más del 50% de error en comparación con la regresión lineal de la medición de tres años consecutivos, disminuyendo la base de datos de 173 a 157 datos totales; esto disminuyó el error promedio del modelo final a la mitad (17,88% a 9%), aproximadamente.

**Procesamiento de series de tiempo:** Se ordenan temporalmente las variables de la base de datos y se debe identificar la variable objetivo asociando la entrada y salida, ya sea para una única predicción temporal o para una variada cantidad de tiempos. Bontempi et al. (2013) presenta un trabajo en que considera la aplicación de ML en problemas de series de tiempo para aprendizaje supervisado.

**Tratamiento de datos ruidosos:** Cuando se recolectan datos no es extraño que se cometan errores humanos, que los instrumentos no se encuentren bien calibrados o que el instrumento de medición se haya modificado a lo largo del tiempo, estos datos se denominan ruidosos. Deben tratarse para asegurar un modelo final generalizable. Sin embargo, algunos investigadores conscientemente han incluido cierta cantidad de errores aleatorios en base de datos con el afán de ver hasta cuantos datos ruidosos acepta el modelo sin cambiar mucho la precisión (Sheng et al., 2011). Algunas técnicas empleadas para abordar datos ruidosos incluyen: recopilación de más datos para generar un modelo más representativo, uso de regularización que agrega un factor de penalización que reduce efectos de sobreajuste, empleo de técnicas de validación cruzada para selección de parámetros de modelos, análisis estadístico para identificar datos extraños, etc.

**Completar datos faltantes:** La ausencia de alguna variable de entrada dentro de la base de datos genera una reducción en la cantidad de ejemplos para entrenar, esto se vuelve complejo si la cantidad de datos con que se cuenta es reducida. En modelos de deterioro se han aplicado técnicas como medias móviles para completar y suavizar series de datos (Jidong Yang et al., 2003) y regresiones (Abdelaziz et al., 2020).

**Selección de base de datos a partir de datos faltantes:** Cuando se tiene una base de datos amplia, se pueden eliminar más datos para trabajar con una base de datos más robusta y precisa. Marcelino et al., (2019), sólo considera datos de LTPP con menos del 30% de datos faltantes y, en el caso de que hay una intervención en la sección, se considera su edad desde la última.



**Modificación de máximos y mínimos:** Consiste en modificar máximos y mínimos dentro de las variables para evitar errores en la modelación. Hollmén & Sirvio, (2011), modifican valores máximos de ahuellamiento e IRI (variables de salida del modelo) redondeándolos a 50 [mm/m] y 20[mm/m], respectivamente.

**Conversión de variables cualitativas:** En algunos casos la base de datos puede recoger variables que pueden considerarse cualitativas como: el tipo de pavimento, tratamiento aplicado a alguna superficie, clima, etc. En estos casos es necesario realizar una conversión a una variable numérica para recoger su efecto en el modelo matemático. En otros casos, se debe hacer el proceso inverso para disminuir el proceso de modelamiento o para poder relacionar mejor el modelo a la variable de salida, en el caso que sea categórica.



**Normalización de variables:** Es una modificación en la base de datos que permite que las variables de entrada no tengan tanta variabilidad entre ellas, haciendo que la media de los datos sea cero y la desviación estándar uno. Mediante la normalización todas las variables de la base de datos se modifican a una escala común, buscando no distorsionar ni perder información. La normalización se puede calcular a partir de la ECUACIÓN 1 y ECUACIÓN 2. Esto permite que los pesos asociados a cada variable indiquen su influencia sobre la variable de salida y que las variables muy grandes no afecten el comportamiento del modelo final. No es conveniente hacer normalización de datos cuando se presentan valores atípicos o ruidosos (Hongren Gong et al., 2018; Jalal et al., 2017). Cuando las variables de entrada tienen distinto significado físico y dimensión, se recomienda normalizar los datos, tal como lo hace Qian, (2010), para predecir el desempeño de pavimentos rígidos de carretera en Shenda, China.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad \text{Ecuación 1}$$

$$x_{stand} = \frac{x - promedio(x)}{Desv. Estándar (x)} \quad \text{Ecuación 2}$$

**Análisis de componentes principales (PCA):** Técnica que disminuye la probabilidad de sobreajuste, simplificando los modelos desarrollados al reducir dimensionalidad y eliminar las correlaciones entre las variables de entrada. Permite la implementación de todas las variables de entrada en el desarrollo del modelo y elimina la correlación entre ellas (Kargah-Ostadi & Stoffels, 2015).

**Partición Recursiva:** Técnica de ML que explora los datos cuando se tiene alta dimensión, clasificando los datos en sub-conjuntos homogéneos según variables independientes. Se obtiene dividiendo el conjunto de datos en todas las posibles combinaciones, siempre y cuando los subconjuntos no se superpongan en la predicción. Según S. M. Piryonesi & El-Diraby, (2020), dividir los datos en diferentes zonas climáticas puede cambiar la importancia relativa de los atributos y la precisión general de los modelos.



### 2.1.5 Mantenimiento, Rehabilitación y Reconstrucción

Se tienen distintas actividades de mantenimiento y rehabilitación aplicadas dependiendo de las condiciones e inversión disponible. La selección de la mejor alternativa para una sección de pavimento dependerá de su condición actual, la posibilidad de adecuación del tratamiento a las condiciones actuales del pavimento, vida útil del tratamiento y costo de aplicar y mantener el tratamiento. Dependiendo del deterioro del pavimento, será posible aplicar una serie de técnicas que permiten reparar o disminuir el deterioro y, así, extender la vida útil del pavimento.

Hay tres niveles de tratamientos de M&R: Mantenimiento de rutina, mantenimiento preventivo pesado y la rehabilitación pesada. El mantenimiento de rutina, es un proceso donde se busca mejorar la condición de la carretera. El mantenimiento preventivo pesado o rehabilitación ligera se refiere al tratamiento aplicado para llevar un camino de estado aceptable a uno excelente. La rehabilitación pesada se aplica cuando el camino ya está en una condición pobre y se rehabilita para llevarlo a condición excelente. Finalmente está el caso de la reconstrucción, en el que se debe cambiar por completo el camino, lo cual es más costoso y se pierde mucho material. Es por esto que, mediante una buena planificación, se pretende evitar llegar hasta este último nivel. (Whiteley-Lagace et al., 2011)

## 2.2 EVALUACIÓN DE CONDICIÓN DE PAVIMENTOS

### 2.2.1 Definición y característica de los Pavimentos

Se define como pavimento a la totalidad de elementos que componen el suelo de una infraestructura vial que tiene como fin proporcionar una capa de rodamiento que permita un tránsito seguro. La satisfacción que proporciona un pavimento se puede determinar en términos de serviciabilidad, resistencia y durabilidad; se pueden determinar de manera objetiva mediante indicadores que determinen el desempeño actual y su proyección en el tiempo.

Principalmente, existen dos tipos de pavimentos: asfáltico y de hormigón, los cuales transmiten los esfuerzos a la subrasante de manera distinta cuando se ven sometidos a cargas. Generalmente, los pavimentos constan de 2 a 3 capas, las cuales pueden usar el mismo o distintos materiales. Las capas de más abajo son de mayor espesor, material granular y son la base de todo pavimento: subrasante y sub-base. Las capas superiores se encargan de distribuir las cargas aplicadas a las capas inferiores. (Y. Dong et al., 2019)

A continuación, se expondrán los distintos tipos de pavimentos encontrados en los documentos leídos, los tipos de modelamiento, factores de influencia en el comportamiento y los indicadores de deterioros más frecuentados.

### 2.2.1.1 Pavimento flexible

Los pavimentos flexibles poseen en su capa de rodadura asfalto y/o concreto asfáltico. El asfalto, también conocido como bitumen, es un mineral resultante de diversos componentes, en su mayoría naturales, que se mezcla con arena o gravilla para pavimentar la red vial. La capa asfáltica es menos resistente y rígida, sensible a cambios de temperatura del clima, características de distribución y diferentes reglas de temperaturas superficiales en el pavimento, afectando la capacidad de carga y desempeño del pavimento. Genera mayores esfuerzos en la subrasante, por lo que necesita mayor cantidad de capas resistentes y con mayores espesores. (Qiu et al., 2020)

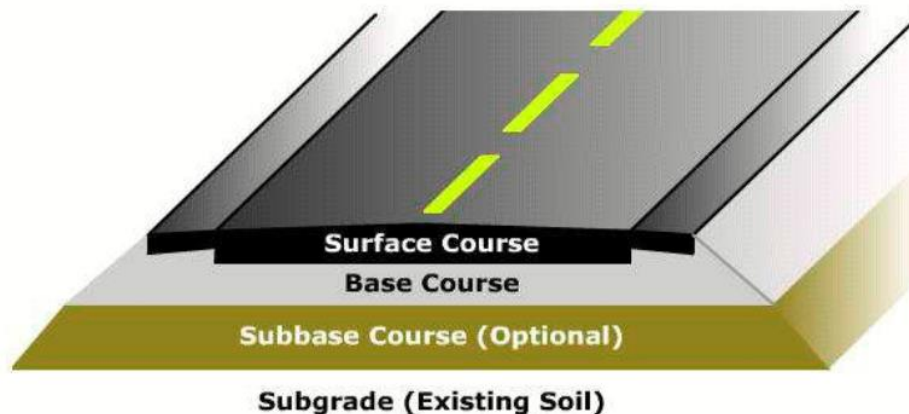




Figura 2: Estructura de pavimento asfáltico (García, 2017)

Cada país o Estado tiene su propia guía de diseño de pavimento asfálticos; sin embargo, todos deben considerar las solicitaciones de tránsito, ciclos ambientales y el comportamiento empírico-mecanicistas de los materiales bituminosos y la estructura. Los pavimentos de concreto asfáltico son más flexible y considerablemente más baratos que un pavimento rígido y tienen un comportamiento viscoelástico-plástico. (Vasquez-Varela & García-Orozco, 2020)

A continuación, se presentan algunos deterioros presentes sólo en pavimentos asfálticos:

- **Ahuellamiento:** Deterioro permanente medido en milímetros producido por las huellas de los neumáticos al estar en contacto con la superficie, provocando un hundimiento longitudinal que corresponde a la acumulación de pequeñas deformaciones; es decir, es la deformación de las huellas que se da en sentido de la circulación de vehículos pesados. Se produce principalmente por altos cambios de temperatura, altas cargas de tránsito repetitivas, compactación inadecuada de la mezcla asfáltica o base, capacidad de soporte insuficiente, mal diseño de la mezcla asfáltica, etc. Hollmén & Sirvio, (2011), establecen el ahuellamiento como una de las evaluaciones superficiales más importantes.



- Permeabilidad: Capacidad que tiene la capa asfáltica para que un fluido la atraviese sin variar su composición, es importante controlarla para evitar la entrada excesiva de agua, que a su vez produce falla prematura. La literatura ha demostrado que depende de los huecos de aire, el espesor de la capa asfáltica, la granulometría de los agregados de la mezcla y el contenido del asfalto. (Nivedya & Mallick, 2018)

#### 2.2.1.2 Pavimento rígido

Los pavimentos rígidos tienen una capa de rodadura de hormigón de cemento muy rígida que funciona como un elemento placa, las capas inferiores son de material granular y/o sub-base. Distribuye los esfuerzos a sus capas inferiores con presiones más bajas, siendo la capa rígida la que aporta mayor capacidad a la estructura. Por lo general son usados para cargas más pesadas y cuando la subrasante tiene propiedades muy pobres. Se ven afectados por cambios de temperaturas.

- Falla de juntas: Levantamiento de juntas, desintegración de bordes o esquinas de las losas, abertura de juntas. Deterioro común de pavimentos rígidos que puede ser causado por deficiencias del sellado, juntas saltadas, contracción o expansión de la losa, etc. Afecta negativamente en la seguridad de conducción y es costosa en su rehabilitación; es por esto que su predicción es esencial en SGP de hormigón y estrategias de diseño de pavimentos. (W. Wang et al., 2017)

#### 2.2.1.3 No Pavimentado



Los caminos no pavimentados en su mayoría tienen una capa de rodadura de grava o con superficies originales, que frecuentan operar a bajo volumen de tránsito. La proyección de M&R es distinta si se tienen caminos de grava o superficie nativa.

#### 2.2.1.4 Pavimento con mejora.

Los pavimentos con mejora son aquellos que han tenido algún tratamiento de rehabilitación o mantenimiento durante su vida útil.

#### 2.2.1.5 Subrasante y capas granulares

- Subrasante: Es la superficie del terreno donde se apoya el pavimento, por lo general está conformada por el suelo natural disponible en el terreno que es preparado con movimientos de tierra y compactación.





- **Sub-base Granular:** Capa de agregados granulares que están compactados y graduados. Se ubica sobre la Subrasante, compuesta principalmente de grava arenosa, libre de material vegetal y terrenos de arcilla.
- **Base Granular:** Capa de agregados pétreos bien compactado y graduado, dispuesta principalmente cuando se tienen pavimentos flexibles. Debe tener alta resistencia a ser deformada, lo cual se asegura estabilizando la capa.

## 2.3 MODELOS DE DETERIORO

### 2.3.1 Introducción

Los modelos de deterioro son la base fundamental de gestión de infraestructura vial, ya que ayudan a crear un sistema de gestión de pavimentos que predice deterioros del pavimento y evalúa la aplicación de diversas técnicas de mantenimiento. Permite organizar y programar intervenciones y brindar herramientas de mantenimiento optimizando tiempo y costo. Puede traducirse en beneficios económicos, ambientales, sociales y aprovechamiento de bienes patrimoniales, manteniendo los indicadores exigidos de serviciabilidad del pavimento y, que así, perdure el tiempo para el que fue diseñado. Además, permite administrar los recursos disponibles en infraestructura para los programas de mantenimiento y evaluar efectos relativos de algunas características de diseño. (Rodríguez Moreno et al., 2013).

Está definido como una expresión matemática que predice la evolución del estado del pavimento en el tiempo en base al conocimiento de sus condiciones al momento de su puesta en marcha y en cualquier momento de su vida útil (Hernan Solminihac et al., 2018). Las prácticas de mantenimiento eficaces y eficientes requieren modelos precisos para la predicción del rendimiento del pavimento; sin embargo, la incertidumbre del tráfico y los factores ambientales, así como la variabilidad de las propiedades de los materiales y los sistemas estructurales del pavimento, son obstáculos para la predicción precisa del desempeño (Fathi et al., 2019).



Los modelos de predicción se pueden dividir en probabilísticos y deterministas, a continuación, se presenta la TABLA 3 con la comparación de ambos modelos de predicción:

*Tabla 3: Tabla comparativa de modelos deterministas y probabilísticos. (W. Wang et al., 2017)*

| <b>MODELO DETERMINISTA</b>   | <b>MODELO PROBABILÍSTICO</b>  |
|--|---|
| Obtiene el valor exacto de la predicción a partir de datos históricos  | Da la probabilidad de que el pavimento tenga un estado en particular, basado en la variabilidad en los factores de predicción.  |
| Son los modelos de predicción más común, se pueden categorizar en mecanicista, empírico y empírico-mecanicista.  | Incluye modelos de Markov, enfoque bayesiano y análisis de supervivencia.   |
| Su ventaja es que son fáciles de entender y desarrollar.   | Las ventajas son que incorpora convenientemente datos de campos, se adapta a aportes subjetivos del personal experimentado, obtiene predicciones de rendimiento con ecuaciones matemáticas, proporciona una distribución probabilística del comportamiento esperado muy útil cuando se tienen secciones que se comportan distinto a lo que se espera y refleja una tendencia de comportamiento independiente de si es lineal o no lineal. |
| Su desventaja es que la regresión de predicción no funciona bien en secciones individuales.  | Las desventajas son que no proporcionan orientación sobre los factores físicos que contribuyen al cambio de condición y que la probabilidad de cambio de condición no depende del tiempo.   |
| Los modelos mecanicistas puros no son capaces de predecir el complejo comportamiento del deterioro de pavimentos con precisión. Los modelos empíricos son capaces de predecir, pero es limitado al alcance y variedad de datos disponibles. La mayoría de los modelos empírico-mecanicistas se usan para predecir a nivel de proyecto. | Las cadenas de Markov basadas en el concepto probabilístico del daño acumulado son las más usadas para predicción de condición de pavimentos. Utiliza un análisis de supervivencia, en el que una de las variables es el tiempo transcurrido hasta que ocurre un evento de interés. Estos tienen enfoques paramétricos, no paramétricos y semi-paramétricos.  |

### 2.3.2 Factores de influencia en el comportamiento del pavimento

Se espera que los pavimentos se desempeñen de manera óptima durante su vida útil. La vida útil es un valor teórico que no necesariamente coincide con el período de tiempo que el pavimento se encuentra en un umbral de condición cuando se encuentra en funcionamiento.

El desempeño del pavimento se ve afectado por varios factores relacionados con las cargas de tránsito, condiciones ambientales, condiciones estructurales, calidad de conducción, mantenimiento, entre otros, que deben considerarse en el diseño de pavimentos, ver FIGURA 3. (Tighe et al., 2007)

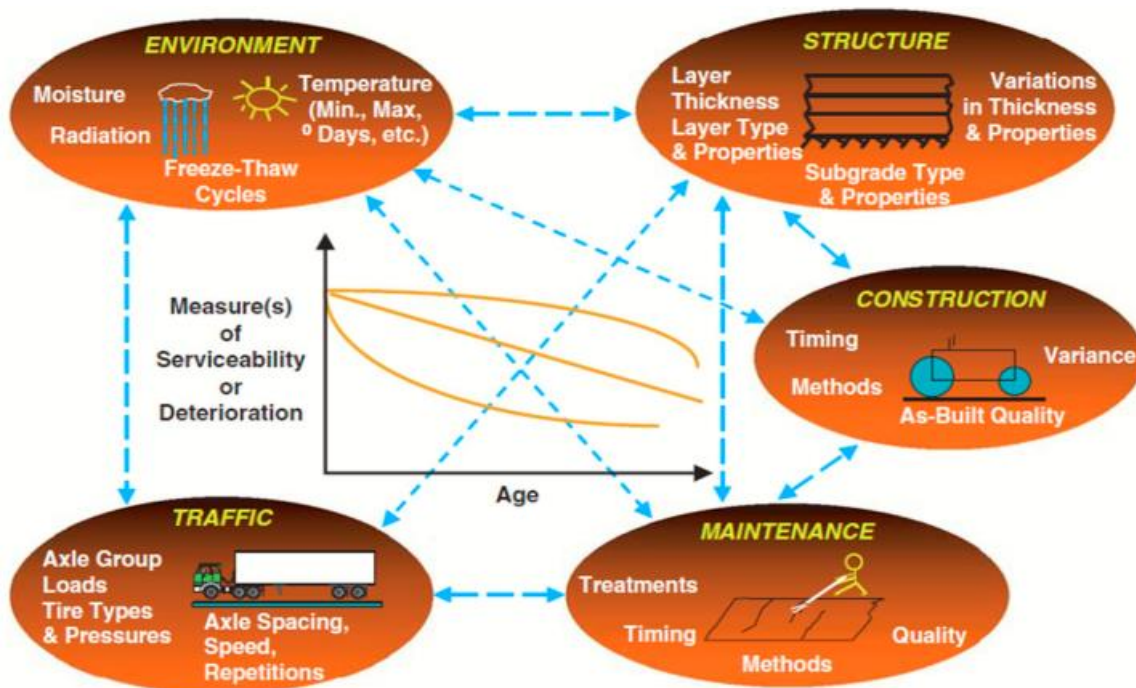




Figura 3: Condiciones que influyen el comportamiento del pavimento. (Tighe et al., 2007)

- **Condiciones climáticas:** Magnifican las tensiones y deterioros de pavimentos rígidos y flexibles. Los pavimentos rígidos son altamente susceptibles a variaciones térmicas entre la fibra superior e inferior de las losas de hormigón, ya que se producen tensiones de alabeo que pueden generar fisuras y grietas por tracción. Los pavimentos flexibles son altamente susceptibles a altas y bajas temperaturas, las altas temperaturas lo vuelven un material viscoso y las bajas temperaturas lo vuelven un material más rígido y frágil, ambos efectos disminuyen su capacidad estructural (Hernán Solminihaç, 2018). Están compuestas por: precipitaciones, temperatura, radiación solar, índices de congelamiento, zonas climáticas, estación del año, etc. Las condiciones ambientales tienen alto impacto en desempeño del pavimento, ya que las bajas temperaturas generan agrietamiento apresurado (Tighe et al., 2007).





- Condición de tránsito: Aplican cargas estáticas y dinámicas sobre el pavimento, los cuales se transforman en ciclos de cargas y descargas que van fatigando progresivamente la estructura del pavimento (Hernán Solminihac, 2018). Bosurgi & Trifirò, (2005a), lo establecen como una forma de cuantificar la condición de uso del pavimento. Están compuestas por: promedio de vehículos diarios, ejes equivalentes, solicitud de vehículos pesados circulantes, velocidad, cargas repetitivas, etc.
- Propiedades estructurales: Determinan la resistencia del pavimento frente a solicitudes de tránsito y medio-ambientales. Están compuestas por: espesor de las capas del pavimento, propiedad de los materiales, tipo de capa, deterioros superficiales o funcionales, etc.
- Método y condición de construcción: Corresponde a las cualidades que hay al momento de construir, define qué tan deteriorado está el pavimento y las externalidades presentes. Están compuestas por: cualidades al momento de construir, método de construcción, tiempo de construcción, índices de deterioro, etc.
- Historial de mantenimiento y rehabilitación: Registra las actividades de M&R presentes en el pavimento, con el fin de definir la vida útil restante debido a las solicitudes presentes. Están compuestas por: tiempo desde tratamiento, tipo de tratamiento, metodología, costo de intervención, etc.

La mayoría de los factores que influyen en el comportamiento del pavimento deben tomarse en cuenta para hacer que el modelo sea más completo; sin embargo, muchos de estos no pueden ser manejados por el diseñador y es necesario aplicar medidas de conservación. Gran cantidad de variables de entrada, la correlación de las variables de entrada, la dificultad para recopilar tantas variables, la forma experimentar de la curva de desempeño, complejidad de ecuaciones finales, entre otros, hacen que la adquisición de datos y el algoritmo del modelo sean más complejos y costosos. Es por esto que es de gran importancia el análisis de sensibilidad (desarrollado en CRITERIOS DE EVALUACIÓN), la revisión bibliográfica y el juicio técnico de especialistas. (Kargah-Ostadi et al., 2010; Kargah-Ostadi & Stoffels, 2015)

### 2.3.3 Evaluación de condición del pavimento

Para asegurar el servicio entregado a los usuarios se deben hacer evaluaciones constantes que consideren seguridad y comodidad al conducir. Las evaluaciones permitirán poner énfasis en el desempeño a estudiar; si el deterioro es superficial, sólo las secciones dañadas deben ser mantenidas, reparadas o rehabilitadas, en cambio, cuando la estructura está deteriorada se debe reconstruir toda la sección de pavimento (S. Dong et al., 2019). Para que estas evaluaciones sean comparables deben ser consistentes y referirse a indicadores que puedan relacionarse o sean conocidos universalmente. Los deterioros se pueden clasificar en funcionales y estructurales:

- Deterioro superficial: Relacionado al nivel de serviciabilidad y seguridad de la vía.
- Deterioro estructural: Relacionado a la pérdida de capacidad del suelo o alguna capa que compone el pavimento.





### 2.3.3.1 Deterioro de predicción

#### Agrietamiento

El agrietamiento por fatiga es el deterioro estructural de pavimentos asfálticos que presenta un desarrollo progresivo. Inicialmente se presenta por grietas longitudinales, que se irán interconectando con otras grietas, formando la “*piel de cocodrilo*”. Se presenta principalmente en las zonas donde hay mayores esfuerzos, por ejemplo, las cargas de tránsito, diferencias de temperatura, fricción, etc. El espesor del suelo o baja capacidad del suelo, mezcla asfáltica muy rígida y el drenaje inadecuado son algunos de los factores que afectan el nivel de servicio de la red de pavimentos. Se predice en términos del área agrietada circunscrita en forma de bloque porcentual dentro del área total de la sección de pavimento. También puede producirse debido a efectos naturales o ser provocados por el hombre, procesos en su mayoría estocásticos (Thube, 2012).

En pavimentos rígidos puede haber agrietamiento de esquina, transversal y longitudinal. El agrietamiento de esquina es producido por falta de apoyo en las losas, bombeo o alabeo térmico, sobrecarga en esquinas, deficiencia en la transmisión de cargas, etc. El agrietamiento longitudinal producido por asentamiento en la base y/o subrasante, losa muy ancha, falta de junta longitudinal, etc. El agrietamiento transversal es causado por losas de largo excesivo, espesor insuficiente, alabeo, etc.

FDOT establece el *Crack Index* (Índice de Agrietamiento, en español) para enumerar las grietas del pavimento y determinar las prioridades de rehabilitación, el cual funciona bien con los modelos empírico-mecanicistas y empíricos cuando se tienen pocos datos (Lou et al., 2001). HDM-4 considera el agrietamiento como uno de los deterioros principales para definir el inicio de destrucción del pavimento, establece dos tipos de agrietamiento: estructural y térmico. El agrietamiento estructural se produce por las cargas de tránsito, edad y condiciones medioambientales. El agrietamiento térmico se produce por cambios extremos de temperatura, por lo que sólo ocurre en algunas zonas geográficas (Pérez & Nuñez, 2005). El agrietamiento térmico es uno de los principales deterioros del pavimento asfáltico, que se produce al principio de su vida útil. Hay dos tipos de agrietamiento térmico, uno se produce por temperaturas muy bajas y el otro por fatiga térmica, es decir, cambios cíclicos de temperatura (Esfandiarpour & Shalaby, 2017).



### Agrietamiento por reflexión:



El agrietamiento por reflexión es un tipo de agrietamiento que inicia en el fondo de la capa y se propaga hacia la superficie. NCHRP 1-41, llevado a cabo principalmente en el *Texas Transportation Institute*, propone modelos validados para predecir el inicio, alcance y gravedad de las grietas por reflexión en superposiciones de HMA. Shafabakhsh et al., (2015), generan un modelo de predicción de deformaciones longitudinales producidas en el fondo de la capa asfáltica de pavimentos flexibles sometidos a cargas en movimiento.

La mezcla asfáltica en caliente (MAC) aplicada sobre pavimento rígido produce agrietamiento por reflexión producido en la unión de las capas, lo que permite que el agua se infiltre en toda la estructura, esto genera costosas reparaciones, demoras e inconvenientes para usuarios, y reduce la vida útil del pavimento. Halil Ceylan et al., (2011), propone un indicador que comprenda el crecimiento estable y progresivo de la grieta bajo diferentes esfuerzos aplicados, denominado *Stress Intensity Factor* (SIF - Factor de Intensidad de Tensión, en español). SIF describe el estado de la tensión en la punta de la grieta, con el fin de comprender el mecanismo subyacente y las causas del agrietamiento reflejante en las superposiciones de HMA en pavimentos flexibles y rígidos. El modelo de predicción de SIF calculará la velocidad a la que la grieta se propagará de manera elástica-lineal; sin embargo, es complejo determinar si la grieta está situada en una geometría 3D compleja o sujeta a un estado de tensión complejo.

### Baches

Según HDM-4, está definido como la cavidad producida en la superficie del pavimento formada por desprendimiento del material con un diámetro y profundidad promedio mayor o igual a 150 [mm] y 25 [mm], respectivamente. Los baches son provocados principalmente por la infiltración de agua a las capas inferiores, la capacidad insuficiente para tránsito pesado y pendientes bajas, por defectos constructivos, etc. Se mide en términos de números de baches con un área de 0,1 [m<sup>2</sup>] por kilómetro. (Heidari et al., 2018; Pérez & Nuñez, 2005)

En conjunto con el agrietamiento por fatiga, son los tipos de daños más críticos en pavimentos flexibles en la MEPDG y, a menudo, rigen el estado general del pavimento. Sin embargo, la función de transferencia es una combinación lineal de deformaciones que no produce predicciones fiables (J. Yang et al., 2006). Hongren Gong et al., (2018), desarrollan dos redes neuronales profundas que pueden ser incluidas a MEPDG para mejorar la precisión de la predicción.



## Condición de Pavimentos

La condición de pavimentos es un índice combinado que considera distintos deterioros ponderados con pesos que representen influencia del deterioro tanto funcional como estructural en el pavimento. Por lo general, es determinado subjetivamente por personal con experiencia, aunque algunas agencias lo determinan con modelos matemáticos.



FDOT establece el *Pavement Condition Rating* (PCR - Clasificación de Condición del Pavimento, en español) para establecer la condición general de pavimento. Resulta del mínimo entre el índice de agrietamiento, índice de conucción e índice de ahuellamiento, todos medidos en una escala de 0 a 10 (peor a mejor condición). Cuando PCR es mayor a 6,4, el pavimento está en buenas condiciones. FDOT determina PCR con dos métodos matemáticos: tasa de deterioro promedio y regresión lineal simple, pero ninguno se ajusta debido a que el comportamiento del pavimento es un fenómeno no-lineal. (Jidong Yang et al., 2003).

Elbagalati et al., (2017, 2018), define el *Structural Condition Index* (SCI - Índice de Condición Estructural, en español) que depende del *Structural Number* (SN - Número Estructural, en español) del pavimento en servicio y el diseñado. SCI es categorizado de la siguiente manera:

- Condición estructural pobre:  $SCI < 0,6$
- Condición estructural suficiente:  $0,6 \leq SCI < 1$
- Condición estructural buena:  $1 \leq SCI < 1,5$
- Condición estructural muy buena:  $1,5 \leq SCI$

## Condición superficial

*Surface Condition Rating* (SCR - Índice de Condición Superficial, en español) es un índice que combina los deterioros superficiales evaluados individualmente, con el fin de crear una sola calificación (Whiteley-Lagace et al., 2011). Además, está el *Structural Distress Index* (SDI - Índice de Deterioro Superficial, en español), uno de los índices funcionales más comunes obtenidos de la encuesta *Road Condition Survey* (RCS - Encuesta del Estado de la Carretera, en español), esta encuesta determina si la estructura del pavimento aun está en buenas condiciones y es capaz de soportar la carga y el volumen del tránsito. Por lo general, se determina en función de las condiciones superficiales del camino: baches, grietas, surcos, ahuellamiento, exudación y el grado de deflexión. (Rosada et al., 2019)



## Desempeño:



La evaluación y predicción del desempeño de pavimentos son unas de las acciones más importantes dentro de un SGP. *Pavement Performance Evaluation Index* (PPEI - Índice de Evaluación de Desempeño del Pavimento, en español) engloba el desempeño funcional, estructural, de seguridad y de comodidad del pavimento, relacionado directamente con la condición estructural y funcional del pavimento, el entorno ambiental y de tránsito. Qian, (2010), analiza los principales factores de influencia del desempeño del pavimento y genera modelos de predicción del desempeño funcional, estructural, de seguridad y de comodidad. MEPDG establece un modelo de agrietamiento térmico para pavimentos de concreto asfáltico con el fin de predecir el comportamiento del pavimento a bajas temperaturas. El modelo requiere calibración local para lograr que tome en cuenta variables de materiales, climáticas y condiciones locales (Esfandiarpour & Shalaby, 2017). Yao et al., (2019), propone un método alternativo que prediga el desempeño del pavimento pero, en vez de modelar un índice, se construyen cinco modelos de predicción: ahuellamiento, IRI, agrietamiento, SFC y condición del pavimento.

## Esfuerzo

El esfuerzo es un indicador que representa la capacidad de los pavimentos para soportar ciertas solicitaciones. MEPDG implementa un modelo de cumplimiento de *creep compliance* (fluencia), tendencia que tiene un material para deformarse permanentemente bajo esfuerzos persistentes. El modelo se basa en el ligante de pavimentos asfálticos y sus propiedades volumétricas (Esfandiarpour & Shalaby, 2017).

## IRI:

*International Roughness Index* (IRI - Índice de Rugosidad Internacional, en español) es uno de los índices de condición más importante, puesto que influye en la calidad de conducción del vehículo y las cargas dinámicas, de los más usados para el comportamiento de pavimentos. Cuantitativamente, está definido como la relación entre la suspensión total del vehículo y la distancia recorrida (Y. Dong et al., 2019; Kargah-Ostadi, 2014). La *Federal Highway Administration* (FHWA, Administración Defederal de Carreteras, en español) lo propuso para predecir el desempeño del pavimento flexible junto al % de baches y grietas, por esto Marcelino et al., (2020), y muchos investigadores lo usan como indicador. Las variables que tienen más influencia en rugosidad son: IRI inicial, edad del pavimento, tránsito, condiciones climáticas (precipitación anual e índice de congelación), propiedades estructurales del pavimento, propiedades de subrasante (humedad y granulometría), drenaje y tratamientos de M&R (Kargah-Ostadi & Stoffels, 2015).



LTPP tiene una baja frecuencia de registro de IRI, medido cada uno o dos años; es decir, en promedio cada pavimento tiene sólo 50 mediciones de IRI, incluso en pavimentos que son más antiguos. La baja consistencia en la base de datos, hace que el pre-procesamiento y las técnicas de rellenado sean procesos más importantes aún (Y. Dong et al., 2019). Existe un equipo de inspección que mide el IRI mediante una cuerda que se mueve verticalmente cuando hay irregularidades en el camino, el valor de IRI será la cantidad de milímetros que se mueve la cuerda en una sección de 1 [metro] de pavimento. (Hollmén & Sirvio, 2011)

### PCI:



*Pavement Condition Index* (PCI - Índice de Condición de Pavimento en español) es el índice más reconocido por el Cuerpo de Ingenieros de EE.UU (Younos et al., 2020) y ampliamente aceptado para describir el desempeño del pavimento según ASTM D6433-09 (Fathi et al., 2019). PCI se expresa mediante un valor numérico que representa la condición del pavimento basado en un sistema de clasificación que va del 0 al 100, donde 0 corresponde a la peor condición y 100 a condición excelente, tal como se muestra en la FIGURA 4. Los factores que influyen PCI son los relacionados con la carga de tránsito (intensidad, frecuencia, eje y configuración de neumáticos), condiciones climáticas (temperatura y precipitación), diseño y construcción inicial, edad del pavimento y efectos de mantenimiento (Younos et al., 2020). PCI refleja el estado del pavimento y, con modelos de comportamiento precisos y simplificados, puede tomar decisiones de actividades de M&R en función a las solicitudes, sin realizar más pruebas.

|     |              |
|-----|--------------|
| 100 | Good         |
| 85  | Satisfactory |
| 70  | Fair         |
| 55  | Poor         |
| 44  | Very Poor    |
| 25  | Serious      |
| 10  | Failed       |

Figura 4: Escala estándar de PCI. (Younos et al., 2020)

### Pérdida de árido:

La pérdida de áridos es la relación entre el área porcentual con pérdida de áridos o materiales y área total. Según HDM-4, la pérdida de áridos es un tipo de deterioro superficial que depende principalmente de la región y su método de construcción (Pérez & Nuñez, 2005). A. S. Oladele, (2013), establece la pérdida de árido como uno de los indicadores locales más importantes, que depende de las variables de tránsito, clima, estructurales, cualidad de áridos en la mezcla, otros deterioros presentes en el pavimento y el inventario de mantenimientos.



## PSI:

*Pavement Serviceability Index* (PSI, Índice de Serviciabilidad del Pavimento, en español) es una clasificación subjetiva de la capacidad de servicio del pavimento introducida por la AASHTO para cuantificar los resultados de la prueba de pavimentos flexibles y rígidos con distintas condiciones estructurales, va de cero (deterioro completo) a cinco (condición perfecta). PSI indica la condición estructural y funcional del pavimento, ya que la serviciabilidad se ve afectada por los deterioros superficiales provocados por la deficiencia de la estructura para soportar las cargas a la que fue diseñada. Por lo general se usa para la predicción de rehabilitación del pavimento. (Bianchini & Bandini, 2010; Tabatabaee et al., 2013)



## Vida útil restante:

*Remaining Service Life* (RSL - Vida Útil Restante en español) está definido como el tiempo en el cual el pavimento se comportará mejor o igual a un cierto nivel funcional y estructural establecido. Karballaezadeh et al., (2019), lo establecen como un umbral mínimo de condición que se mantiene con tratamientos de rutina; en cambio, para Nabipour et al., (2019), es un índice que estima el tiempo en que se vuelve esencial aplicar técnicas de reparación o reconstrucción. RSL es un buen indicador para modelos de deterioro, ya que es un factor flexible y no se limita a métodos actuales y costosos y puede ser determinado con evaluaciones superficiales y no destructivas del pavimento. Existen métodos mecánicos y empíricos para determinar el RSL, los estudios han demostrado que depende principalmente de las solicitaciones de tránsito y fuerzas externas (Karballaezadeh et al., 2019). Elbagalati et al., (2018), descubre que hay alta correlación entre RSL y SCI,  $R^2 > 0,9$ .

## OTROS:

BCCI: S. Dong et al., (2019), establecen *Base Core Condition Index* (BCCI - Índice de Condición del Núcleo Base, en español) como la suma de cuatro indicadores: integridad de núcleos (0 a 40), dureza de los núcleos (0 a 20), suavidad de la pared interior del núcleo (0 a 30) y conexión entre dos hiladas (0 a 10). BCCI tiene un valor resultante de 0 a 100, mientras más grande el pavimento está en mejores condiciones.



Equivalent Single Axle Load (ESAL): *Equivalent Single Axle Load* (ESAL - Carga de un Eje equivalente, en español) es un concepto desarrollado por la *American Association of State Highway Officials* (AASHTO - Asociación Estadounidense de Oficiales de Carreteras Estatales, en español) en las evaluaciones de carreteras para definir una relación que compare el daño que provocan las diferentes cargas de tránsito. Es un índice estadístico que resume la carga de tránsito equivalente acumulado en un sólo eje de 80 [kN], complejo de calcular cuando se quiere proyectar en un pavimento durante su vida útil. (Tiğdemir, 2014)



---

Fricción: La fricción es una medida de la resistencia al deslizamiento de la llanta/pavimento cuando la superficie está mojada, que puede disminuir en el tiempo. Depende del tránsito, condiciones ambientales y características superficiales del pavimento. La resistencia al deslizamiento del pavimento asfáltico es importante para la seguridad vial. El dispositivo de medición lo evalúa con el número de fricción (FN, Friction Number), que relaciona la fuerza horizontal en la interfaz llanta-pavimento y la fuerza normal sobre la llanta cuando la rueda está completamente bloqueada (Marcelino et al., 2017). *Sideway Force Coefficient* (SFC - Coeficiente de Fuerza Lateral, en español) es un coeficiente que representa la resistencia al deslizamiento de los vehículos que circulan en el pavimento (Yao et al., 2019).

Temperatura superficial: Es la temperatura presente en la superficie del pavimento. Según, Qiu et al., (2020), es un factor importante en los pavimentos asfálticos, ya que afecta la rigidez de la capa asfáltica, lo que impacta la seguridad de tránsito de usuarios. Actualmente se predice mediante métodos estadísticos y análisis de regresión lineal, que no garantizan la precisión de los modelos.



## CAPÍTULO 3. MACHINE LEARNING

El *Machine Learning* (ML – Aprendizaje Automático, en español) estudia cómo permitir que las máquinas tengan la capacidad de aprender. Es un tipo de modelamiento que da soluciones automáticas a problemas complejos y que son difíciles de programar con métodos convencionales, permitiendo que las máquinas realicen predicciones exitosas aprendiendo de experiencias pasadas. Las herramientas de ML han demostrado ser eficientes para encontrar solución a problemas complejos, es por esto que han tenido un gran avance en el último tiempo, además, del aumento de la capacidad de almacenamiento y potencia de procesamiento. Muchas de las cosas que hacemos actualmente están automatizadas mediante ML, como la búsqueda en internet, traductor de google, reconocimiento de voz, entre otros (Rebala et al., 2019a).

Uno de los pioneros de ML es Arthur Samuel quién creó una computadora con la capacidad de aprender de su propia experiencia de juego en el tablero ajedrez. Otros como Rosenblatt (1957) formularon uno de los primeros algoritmos de aprendizaje conocido como perceptrón, cuyo modelo básico sería la clave para el origen a las *Artificial Neural Networks* (ANN - Redes Neuronales Artificiales, en español). A pesar de estos avances, no fue hasta mediados del año 2000 que comenzó otro apogeo, según Rebala et al. (2019) esto se debió en gran parte por la potencia de cómputo, respaldada por una vasta capacidad de memoria y almacenamiento y algoritmos mejorados que fueron optimizados para trabajar con gran conjunto de datos. La metodología de ML genera un algoritmo que aprende de la base de datos; es decir, se enfoca en el fin y no en el cómo. En cuanto se tenga una base de datos más completa y robusta, más preciso será el modelo.

En este capítulo se verán las relaciones entre ML, inteligencia artificial (IA) y DL. También, el procedimiento para desarrollar los modelos, las herramientas y conceptos de ML, metodología de modelamiento y evaluación de modelos. Estos conceptos son vitales para comprender el CAPÍTULO 4. Se dará más énfasis en la aplicación de los modelos y sus ventajas y desventajas, en vez de caer en la deducción estadística y expresión matemática.

### 3.1 IA v/s ML v/s DL

La inteligencia artificial (IA) es la simulación de procesos de inteligencia humana desarrollado por máquinas, en especial sistemas informáticos. IA desde hace más de seis décadas ha sido una herramienta prometedora, sin embargo, muchas veces fue difícil de comprobarlo debido a que los procesadores no eran capaces de procesar ni almacenar tanta información y, como ya se dijo, la base de datos es uno de los pilares fundamentales dentro de esta metodología (Rebala et al., 2019a). ML es subconjunto de IA y DL es subconjunto de ML, por lo tanto, ML y DL son herramientas que complementan la IA. Las técnicas de ML son empleadas principalmente para el reconocimiento de patrones, clasificación, aproximación de funciones, predicción, etc (Kargah-Ostadi & Stoffels, 2015).

DL mejora la capacidad de las ANNs añadiendo alta cantidad de capas y niveles jerárquicos que son capaces de aprender mejor que modelos más superficiales. Estas técnicas sin lugar a dudas han logrado innumerables avances entre los que se destacan la capacidad de resolución de problemas casi al nivel humano como: clasificación de imágenes, reconocimiento de voz, transcripción de escritura humana, traducción automática, capacidad de responder a preguntas en lenguaje humano, conducción autónoma de vehículos entre otros señalados por Chollet (2018) en su libro “*Deep Learning with Python*”.

### 3.2 Programación con ML v/s programación tradicional

En la programación tradicional hay un proceso manual en la que una persona o programador crea el modelo, formulándolo matemáticamente o codificando las reglas del modelo. Es decir, las fórmulas o reglas programadas utilizan los datos de entrada para producir la salida deseada. En cambio, la programación con ML crea un programa que es alimentado de los datos de entrada y salida y, por lo tanto, el algoritmo se formula automáticamente a partir de los datos, tal como se ve en la FIGURA 5.

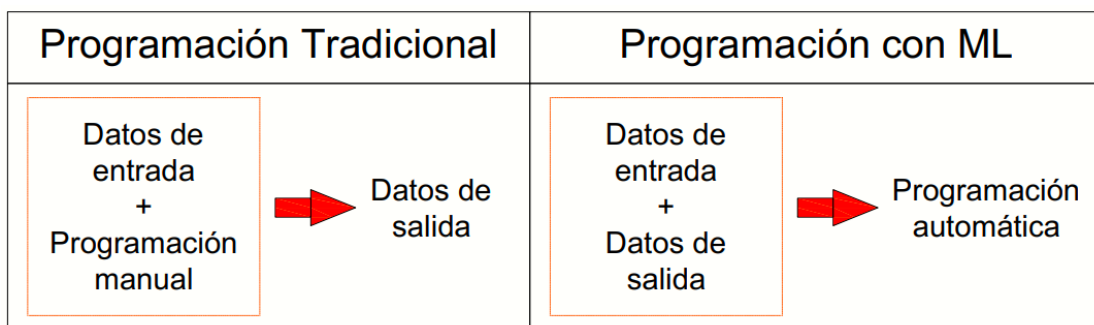


Figura 5: Comparación programación tradicional y programación con ML.

### 3.3 Procedimiento de desarrollo de modelos de predicción mediante ML

Se propone un marco general para el desarrollo de modelos de comportamiento de pavimento mediante el uso de herramientas de ML, ver FIGURA 6.

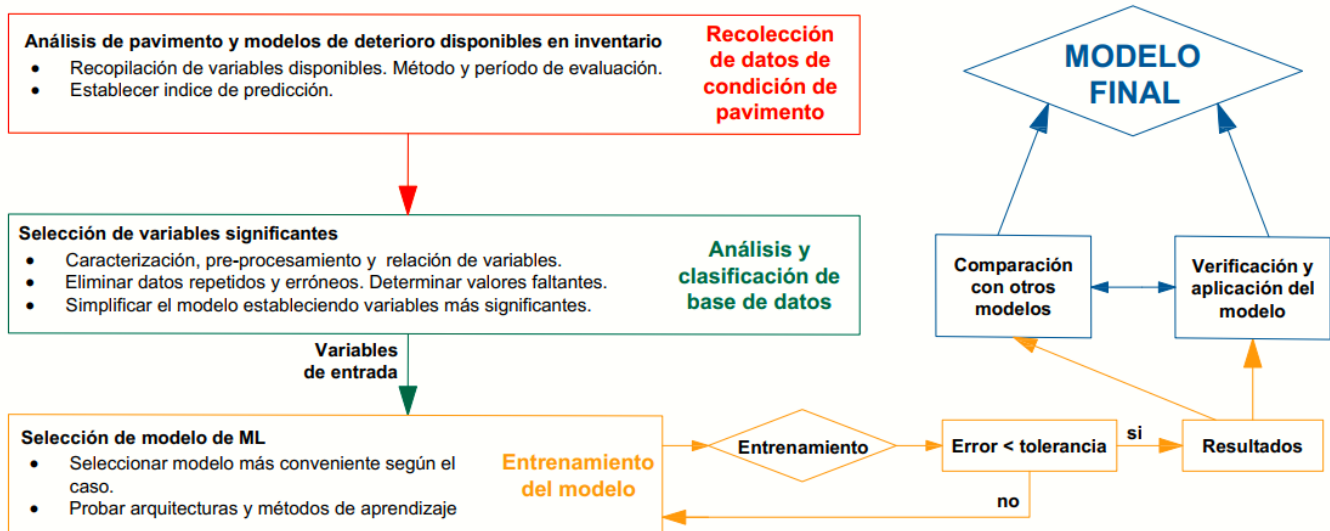


Figura 6: Procedimiento de construcción de modelo de deterioro con herramienta de ML, basado en (S. Dong et al., 2019)

## Recopilación de Datos:



Por lo general la base de datos proviene de dos fuentes: Agencias de transporte (propias de cada sector) y fuentes públicas disponibles. En los casos en que no hay suficientes datos sometidos a las condiciones que se quieren estudiar, se hace una toma de muestras personalizada y enfocada al deterioro que se pretende estudiar o se generan datos sintéticos con algún software conocido. En INVENTARIO están las bases de datos más frecuentes en la bibliografía leída.

## Pre-procesamiento de datos:

Siguiente a la recopilación de datos, el pre-procesamiento de datos se encarga de verificar que los datos disponibles generen un conjunto completo, limpio y adecuado. Para esto se hace un análisis exploratorio identificando valores inusuales, extremos, incompletos, discontinuidades, etc. Esto garantiza la variabilidad y robustez en la base de datos. Según Kotsiantis et al. (2006) la mayoría de los algoritmos dependen fundamentalmente de la etapa de pre-procesamiento de datos, es uno de los procesos más importantes para asegurar buenos resultados.

## Modelado:

Se realiza luego del pre-procesamiento. Puede haber distintos algoritmos de ML aplicables para un mismo problema; primero se debe determinar el objetivo del problema y diferenciar si es o son una/unas variable/s categórica/s o discreta/s. Luego, mediante ensayos de prueba y error, se logra obtener la mejor herramienta para el modelo.



## Evaluación:

Luego, se debe evaluar el desempeño del modelo y, si es necesario, realizar cambios incrementales que disminuyan errores. La evaluación permite identificar oportunidades de mejora e iniciar un proceso iterativo que haga el modelo más preciso y generalizable.

## Modelo final:

Se realiza una evaluación final usando un conjunto de datos de prueba, completamente distinto al conjunto de entrenamiento y validación, que asegure el buen comportamiento del modelo en nuevas situaciones. Luego, el modelo estará listo y completo para ser usado en predicciones.

## 3.4 Aprendizaje



Los algoritmos de ML aprenden y resuelven problemas a través de la experiencia. La forma en que el algoritmo aprende a determinar los valores de salida es lo que se conoce como tipo de aprendizaje. El modelo de aprendizaje usado depende de cómo están los datos dentro de la base de datos, cuando se conoce la respuesta correcta se dice que es un *dato etiquetado* y en el caso contrario se denomina *dato no etiquetado*. Se identifican 4 categorías: aprendizaje supervisado, no supervisado, semi supervisado y reforzado, las cuales serán descritas a continuación, a partir de lo obtenido en el libro “*An introduction to machine learning*”. (Rebala et al., 2019b)

**Aprendizaje supervisado:** El modelo es entrenado con datos etiquetados, es decir, debe aprender las características principales para determinar la respuesta. Se divide principalmente en dos tipos de problemas: clasificación (variable discreta) y regresión (variable continua).

**Aprendizaje no supervisado:** El modelo es entrenado con datos no etiquetados, donde debe identificar similitudes dentro de la base de datos. En general los problemas que pueden resolverse con este tipo de aprendizaje son del tipo *clustering*.

**Aprendizaje semi-supervisado:** Es un intermedio entre el aprendizaje supervisado y no supervisado, el modelo es entrenado con datos en los que algunos están etiquetados. El modelo agrupa los datos y usa los que tienen etiqueta para clasificar los que no la tienen. Asocia los datos etiquetados con respuestas correcta y asume que los que no son etiquetados poseen la misma distribución.

**Aprendizaje reforzado:** El modelo aprende a medida que va detectando variaciones en el entorno, elige una acción que maximice el objetivo y se base en su propio estado y el entorno. No se tienen respuestas correctas para un problema en particular dentro del set de datos; sin embargo, estas son remplazadas por alguna función de recompensa que debe ser maximizada ante determinada acción. En estos problemas el aprendizaje es por prueba y error en un ambiente dinámico.



### 3.4.1 Entrenamiento, validación y testeo

**Sobreajuste:** Por lo general ocurre cuando se tiene una base de datos pequeña, donde la curva memoriza los datos de entrenamiento y no es capaz de generalizar, por lo que no dará un buen resultado con un nuevo punto de prueba. Esto se puede corregir aumentando el parámetro de regularización o la base de datos. En este caso se obtiene un error en el conjunto de datos de entrenamiento muy bajo y de validación muy alto (Marcelino et al., 2019; Rebala et al., 2019a).

**Sub-ajuste:** El modelo engloba muy pocas características, no tiene en cuenta las diversas relaciones. Esto se puede evitar agregando variables de orden superior y/o aumentando el parámetro de regularización. Esto ocurre cuando tanto el error de los datos de entrenamiento y validación son altos (Rebala et al., 2019a).

## 3.5 Herramientas de Machine Learning y Deep Learning

A continuación, se presentan las herramientas de ML y DL más usadas, su descripción, deducción, ventajas y desventajas.

### 3.5.1 Regresión



El modelo de regresión es una técnica estadística que puede hacer predicciones a partir de datos etiquetados. Su metodología de aprendizaje es encontrar relaciones entre varios datos para hacer predicciones. Hay dos tipos de regresión:

#### **Regresión Lineal:**

En la Regresión lineal, la variable a predecir es continua, donde se asume que la relación entre las variables se puede representar con una función lineal. La ECUACIÓN 3 representa la forma genérica del modelo *Multivariable Linear Regression* (MLR - Regresión Lineal Multi-variable, en español), la cual también es denominada “*función de hipótesis*” ( $h_0$ ).

$$y = \theta_0 + \theta_1 * x_1 + \theta_2 * x_2 + \theta_3 * x_3 + \dots + \theta_n * x_n + \varepsilon \quad \text{Ecuación 3}$$

Donde  $y$  es la variable que se quiere predecir,  $x_i$  variable  $i$ -ésima independiente que tiene influencia en  $y$ ,  $\theta_i$  es el coeficiente que determina la contribución que tiene  $x_i$  en el valor de  $y$  y  $\varepsilon$  es el error.



MLR puede tener un solo predictor que debe ser continuo o múltiples predictores que pueden ser continuos o categóricos. El algoritmo se obtiene iterando los valores  $\theta_i$ , de tal manera que al comparar la respuesta del modelo con el valor medido tengan el menor error asociado. (Sylvester Inkoom et al., 2019; Rebala et al., 2019a)

*Multivariate adaptive regression splines* (MARS - Splines de Regresión Adaptativa Multivariante, en español) es un algoritmo que combina la partición recursiva y el ajuste de ranuras con el fin de que se conserven mejor los aspectos positivos de ambos y sea menos vulnerable a sus propiedades desfavorables. MARS utiliza expansiones en funciones de bases lineales por parte, durante la progresión hacia adelante, busca las constantes del modelo y en el paso a paso hacia atrás se eliminan las funciones básicas que reducen la precisión predictiva del modelo. (Kırbaş & Karaşahin, 2016)

### Regresión Logística:

La Regresión logística, es una herramienta de clasificación donde la variable a predecir es una decisión binaria, en las que se tienen dos posibles respuestas. Es la transformación de la Regresión lineal usando una *función Sigmoide*, que representa la probabilidad de que ocurra un evento y opere dentro del rango 0 a 1 (ECUACIÓN 4). Con regresión logística puede modelar un clasificador binario y un clasificador multi-clase. (Heidari et al., 2018; Rebala et al., 2019a)

$$g(z) = \frac{1}{1 + e^{-z}} \quad \text{Ecuación 4}$$

Donde  $z$  es la regresión lineal mostrada anteriormente (ECUACIÓN 3).

Tabla 4: Ventajas y desventajas de la regresión logística.

| VENTAJA   | DESVENTAJA   |
|---|--|
| <ul style="list-style-type: none"><li>• Fácil de entender.</li><li>• No es susceptible al sobreajuste.</li><li>• Rápido de entrenar.</li><li>• Fácil de entrenar cuando se tienen muchos datos.</li></ul> | <ul style="list-style-type: none"><li>• Se le hace difícil resolver problemas no lineales.</li><li>• Valores atípicos son muy influyentes en la respuesta.</li></ul> |

### 3.5.2 Support Vector Machine

*Support Vector Machine* (SVM, Máquina de Vector de Soporte, en español) es un algoritmo de ML introducido a principios de la década de los 90s capaz de resolver problemas lineales y no lineales. Es un proceso iterativo en el que se construye un hiper-plano que maximiza el margen de separación entre las clases de datos. Tiene muy buenos resultados cuando los datos son separables. (Kargah-Ostadi & Stoffels, 2015; Rebala et al., 2019a; Ziari, Maghrebi, et al., 2016).

Puede manejar datos que no sean linealmente separables, mapeando los datos en un espacio dimensional superior usando *funciones de kernels*. Convierte un espacio dimensional no lineal inferior en uno superior para volverlo linealmente separable. Los parámetros del modelo se van iterando hasta encontrar la combinación con mejor precisión para un conjunto de la base de dato (Rebala et al., 2019a; Tabatabaee et al., 2013).




Figura 7: Ejemplo de hiper-planos de separación generados con SVM en problema lineal; donde la línea central y maciza representa el hiper-plano óptimo.

Tabla 5: Ventajas y desventajas de los modelos SVM. (Rebala et al., 2019a; Tabatabaee et al., 2013; Yan & Zhang, 2011)

| VENTAJA  | DESVENTAJA  |
|--|---|
| <ul style="list-style-type: none"> <li>• Puede resolver problemas no lineales.</li> <li>• Puede operar con pocos datos.</li> <li>• Velocidad de aprendizaje rápida.</li> <li>• Capacidad de generalización óptima, global y fuerte.</li> <li>• Capacidad de trabajar con datos que son escasos en la base de datos.</li> <li>• Buenos resultados cuando los datos son separables.</li> <li>• Útil para resolver problemas de altas dimensiones; incluso cuando el número de dimensiones es mayor al número de muestras.</li> <li>• Útil cuando se tienen pocos datos de entrada y número de características algo.</li> </ul> | <ul style="list-style-type: none"> <li>• Requiere recursos informáticos computacionales cuando se tiene más de una variable independiente o problemas no-lineales.</li> <li>• Necesita seleccionar una buena función de kernel.</li> <li>• Difícil de interpretar.</li> <li>• Es complejo de encontrar el (o los) hiper-plano(s) óptimo(s) del sistema.</li> <li>• Si el número de características es mayor al número de muestras, el término de regularización es crucial.</li> <li>• No proporciona directamente estimaciones de probabilidad; estas se podrán determinar mediante validación cruzada, lo que significa un costo tecnológico grande.</li> <li>• Muy lento de entrenar cuando se tienen muchos datos.</li> </ul> |

Ha sido aplicado con éxito para resolver problemas de clasificación (Support Vector Classification) y luego se expandió a regresión (Support Vector Regression) considerando la regresión como una clasificación simple (ver FIGURA 8):

- Support Vector Classification (SVC): Modelo de SVM usado para resolver problemas de clasificación. El modelo genera un plano de clasificación que separe los conjuntos maximizando la distancia. (X. Wang et al., 2020)
- Support Vector Regression (SVR): Modelo de SVM usado para resolver problemas de regresión. Nabipour et al., (2019), primero mapea la información no lineal en un espacio dimensional superior y luego resuelve un problema de regresión lineal en el nuevo espacio; en cambio, X. Wang et al., (2020), encuentra un plano de regresión en el que todos los datos se encuentren lo más cercano. Ambos métodos son aceptables.






Figura 8: Diferencia entre SVC (izquierda) y SVR (derecha). (X. Wang et al., 2020)

### 3.5.3 Decision Tree & Random Forest

#### Decision Tree

*Decision Tree* (DT - Árbol de Decisión, en español) es modelo de ML basado en la toma de decisiones dependientes de valores aleatorios que emplea pruebas estadísticas y métodos no paramétricos para tomar un camino u otro. La respuesta puede ser continua (numérica) o categórica (binaria o multi-clase). También es conocido como *Classification and Regression Tree* (CART - Árbol de Clasificación y Regresión, en español).



Se estructura mediante nodos, donde cada nodo representará la toma de una decisión, lo que determinará el camino que debe tomar hasta llegar a un nodo terminal. El nodo terminal es el resultado del DT, es decir, la predicción. Tener en cuenta que esta decisión puede ser binaria o múltiple; sin embargo, siempre habrá sólo un camino que tomar en cada nodo.

Construir un DT es sencillo, incluso se puede hacer a mano si se tienen pocos elementos de decisión. Primero se deben identificar las variables más influyentes, luego establecer la raíz del árbol con la variable más influyente y definir las decisiones de modo recursivo hasta llegar al nodo terminal. Se vuelve complejo cuando se tiene gran cantidad de variables, ya que es difícil identificar las variables de más importancia. (S. Inkoom et al., 2019; Rebala et al., 2019a)

### **Random Forest**

Random Forest (RF - Bosque Aleatorio, en español) modelo de ML eficaz e intuitivo usado para problemas de clasificación y regresión, también denominada técnica de regresión por conjunto. Da una alternativa para reducir la varianza combinando diferentes modelos de DT mejorando la precisión que se obtiene sólo con uno. Para modelarlo se debe dividir la base de datos en varios conjuntos de entrenamiento.

Bootstrap es una técnica de muestreo complemento de RF que combina las características de los datos para obtener nuevos conjuntos y evitar el muestreo repetitivo, lo que reduce la varianza de los datos sin aumentar el sesgo durante el entrenamiento. Luego, se entrena cada uno de estos conjuntos con algoritmos de aprendizaje supervisado y, por último, se promedian los resultados anteriores (todos los árboles recibirán el mismo peso) o se elige el árbol más frecuente para obtener el modelo final. (Fathi et al., 2019; Sylvester Inkoom et al., 2019; Marcelino et al., 2019; Rebala et al., 2019a).

A continuación, se presenta la TABLA 6 con las ventajas y desventajas de los modelos DT y RF.




Tabla 6: Comparación de modelos DT y RF, con sus respectivas ventajas y desventajas. (Fathi et al., 2019; H. Gong et al., 2018; Sylvester Inkoom et al., 2019; Marcelino et al., 2019; Rebala et al., 2019a)

|                      | <b>VENTAJAS</b>  | <b>DESVENTAJAS</b>  |
|----------------------|--|---|
| <b>Decision Tree</b> | <ul style="list-style-type: none"> <li>• Puede predecir variables de clasificación y regresión.</li> <li>• Requiere poca preparación de datos.</li> <li>• Fácil de construir cuando se tienen pocas variables de decisión.</li> <li>• Facilita la interpretación y visualización de las características del modelo final.</li> <li>• Es capaz de determinar las variables más importantes para obtener la respuesta.</li> <li>• Útil en casos multi-dimensionales.</li> <li>• Capacidad para resolver problemas no-lineales.</li> </ul>  | <ul style="list-style-type: none"> <li>• Siempre habrá sólo un camino que tomar, aunque el modelo sea binario o multi-variable.</li> <li>• No determina un resultado óptimo global, la respuesta siempre dependerá del camino tomado.</li> <li>• Propenso a sobre-ajustar.</li> <li>• Si se tienen muchos nodos, se necesitarán más datos para obtener el modelo.</li> <li>• Se crean árboles sesgados si alguna clase es dominante o hay datos atípicos.</li> <li>• Baja capacidad predictiva en comparación con modelos de regresión de mínimos cuadrados.</li> </ul> |
| <b>Random Forest</b> | <ul style="list-style-type: none"> <li>• Puede predecir variables de clasificación y regresión.</li> <li>• Buen comportamiento predictivo.</li> <li>• Logra mayor precisión que DT.</li> <li>• Puede aprender patrones altamente irregulares con datos de alta dimensión.</li> <li>• Puede trabajar en paralelo.</li> <li>• No necesita transformación de ninguna variable.</li> <li>• Programación eficiente con una base de datos alta.</li> <li>• Bootstrap aborda problemas de sobre-ajuste.</li> <li>• Logra una variación reducida al combinar diversos DTs. Se obtiene un mejor modelo en general, debido a la disminución de la varianza.</li> <li>• Es un método eficaz para estimar datos perdidos y mantiene la precisión del modelo cuando hay varios datos perdidos.</li> </ul> | <ul style="list-style-type: none"> <li>• Susceptible a sobre-ajustar el modelo cuando hay variables categóricas de alta cardinalidad.</li> <li>• Difíciles de interpretar.</li> <li>• No se calibra automáticamente cuando hay nuevos datos.</li> <li>• Modelamiento lento si hay gran cantidad de árboles y mayor profundidad.</li> </ul>  |

### 3.5.4 Naïve Bayes

Naïve Bayes es un algoritmo probabilístico de ML que simplifica la clasificación construyendo suposiciones de independencia entre las variables de predicción y una respuesta determinada. Mejora el proceso de estimación de parámetros combinando conocimientos previos y datos existentes. Los conocimientos previos pueden ser juicios de expertos, experiencias, alguna base de datos antigua o análisis de datos previos.

$$P(c|x) = P(x|c) \cdot P(c)/P(x) \quad \text{Ecuación 5}$$

Primero, la base de datos de conocimientos previos se transforma a una base de datos tradicional, luego se combina con los datos existentes y se analizan mediante el Teorema de Bayes (ECUACIÓN 5), ver FIGURA 9.

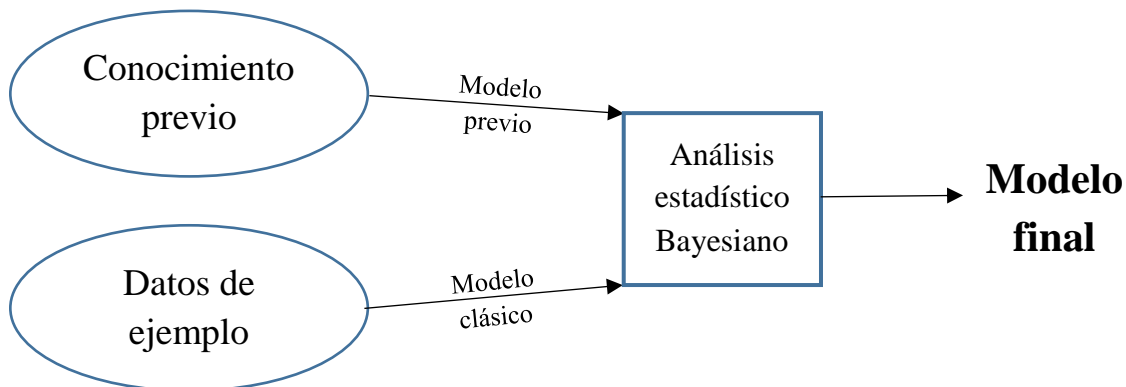


Figura 9: Procedimiento general en modelamiento con Naïve Bayes.(Parvini, 2002)

El clasificador Naïve Bayes usa varios algoritmos para asignar etiquetas de clase y usa el método de máxima verosimilitud para estimar los parámetros. (Sylvester Inkoom et al., 2019; Rebala et al., 2019a). A continuación, se presenta la TABLA 7 con las ventajas y desventajas de modelar con Naïve Bayes:





Tabla 7: Ventajas y desventajas de Naïve Bayes. (Sylvester Inkoom et al., 2019; Parvini, 2002; Rejala et al., 2019a)

| VENTAJA  | DESVENTAJA  |
|--|---|
| <ul style="list-style-type: none"><li>• Altamente escalable.</li><li>• Fácil y rápido de implementar.</li><li>• Fácil de entender.</li><li>• Buena alternativa para simplificar problemas de clasificación.</li><li>• No se necesita la base de datos completa para desarrollar el modelo, siempre y cuando sea significativa.</li></ul> | <ul style="list-style-type: none"><li>• Algoritmo supone que todas las variables de entrada son independientes.</li><li>• Requiere de varias características para aprender una tarea.</li><li>• Se deben hacer ajustes en los modelos previos para poder usarlos y en el resultado para que pueda ser aplicado.</li></ul> |

### 3.5.5 K – Nearest Neighbors

*K-nearest neighbors* (KNN - K – Vecinos más Cercanos, en español), algoritmo de ML no paramétrico que puede ser usado para problemas de clasificación y regresión. Se basa en el supuesto de que los datos cercanos a un punto en particular tendrán características similares al encontrar la clase de elementos de mayor cantidad que esté cerca al punto y definirían una clase dentro de la base de datos. No hay un algoritmo de aprendizaje definido, el modelo se obtiene haciéndole un seguimiento a todos los datos, por lo que se vuelve tedioso cuando la base de datos es muy amplia. Para resolver problemas de regresión se trabaja con el promedio de los K datos más cercanos; sin embargo, KNN es comúnmente usado para clasificación. (Sylvester Inkoom et al., 2019; Rejala et al., 2019a).

La distancia entre los datos de puede determinar con:

- Distancia Euclidiana: Determina cuál de los K vecinos más cercanos del conjunto de datos de entrenamiento se parece más a la nueva entrada del conjunto de validación.
- Distancia de Hamming: Calcula las distancias entre vectores binarios.
- Distancia de Manhattan: Calcula la distancia entre vectores reales mediante la suma de la diferencia absoluta.
- Distancia de Minkowski: Generalización de las distancias Euclidianas y de Manhattan.

Cuando hay más de una clase cercana se pueden asignar pesos dependiendo de la distancia a la que están del punto de interés; es decir, un dato que esté más cerca tendrá mayor influencia en la etiqueta del punto que un dato más lejano.





Tabla 8: Ventajas y desventajas de KNN (Sylvester Inkoom et al., 2019; Rebala et al., 2019a).

| VENTAJA   | DESVENTAJA  |
|---|---|
| <ul style="list-style-type: none"><li>• Algoritmo simple de explicar, comprender e interpretar.</li><li>• No hace suposición sobre la distribución funcional de los datos.</li><li>• Entrenamiento rápido.</li><li>• No necesita una base de datos amplia.</li><li>• Puede resolver problemas extremos de multiclase.</li></ul> | <ul style="list-style-type: none"><li>• Algoritmo sensible a todos los datos, incluso cuando se tengan variables irrelevantes en el problema.</li><li>• No es eficiente cuando se tienen clases de datos sesgadas, ya que influirá el mayor conjunto de datos dentro de la base de datos.</li><li>• Costoso y lento para calibrar nuevos datos.</li><li>•</li></ul> |



### 3.5.6 Programación Genética

*Genetic Programming* (GP - Programación Genética, en español), es una herramienta de ML introducida como una técnica de computación evolutiva basado en el principio darwiniano de la “*supervivencia del más apto*”. Se representa como un DT compuesto por nodos de conjunto de funciones (operadores aritméticos o condicionales) y terminales (entradas y constantes). GP automáticamente selecciona los nodos, por lo general se proporciona un conjunto de datos simples y se van agregando sólo si es necesario. Relaciona todo el espacio de soluciones de problemas discretos y de clasificación y llega fácil al modelo óptimo global. Los modelos de clasificación y ajuste de funciones se evalúan y controlan con estadísticas de  $R^2/t$  – punto y tasa de aciertos, respectivamente. (Chang et al., 2008)

El procedimiento evolutivo consta de tres operadores principales:

- Cruce: Intercambia subárboles de los “*nodos padres*” para reproducir a los “*nodos hijos*” usando selección de apareamiento.
- Mutación: Elige aleatoriamente un nodo de un sub-árbol y lo reemplaza en otro creado aleatoriamente.
- Reproducción: Selecciona la mejor solución de nuevas generaciones producidas a partir de dos padres.

*Gene Expression Programming* (GEP - Programación de la Expresión Genética, en español) es un tipo de algoritmo genético práctico para obtener la solución a modelos de predicción. Se compone principalmente de una población de soluciones matemáticas que evolucionan al mejor resultado mediante un proceso de optimización.



Comienza con la selección de un conjunto de funciones (matemáticas y lógicas) y un conjunto de salidas, luego carga la base de datos en el modelo para evaluar la función de aptitud y crear una población aleatoria inicial de cromosomas. Para cada programa se crean árboles de expresión para ejecutar el programa y evaluar los criterios de aptitud. Luego, los programas seleccionados se reemplazan con la población inicial. Este proceso se itera durante un número determinado de generaciones o hasta llegar a la selección de la mejor solución (M. Mazari & Rodriguez, 2016).

Tabla 9: Ventajas y Desventajas de GP (Chang et al., 2008).

| <b>VENTAJA</b>   | <b>DESVENTAJA</b>   |
|--|---|
| <ul style="list-style-type: none"><li>• Obtiene fácil y rápido el modelo óptimo global.</li><li>• Resuelve problemas discretos y de clasificación.</li><li>• Tiene la capacidad de actualizarse automáticamente.</li></ul> | <ul style="list-style-type: none"><li>• El conjunto de funcionales y terminales deben variar lo suficiente para representar el conjunto de entrada y salida.</li><li>• Profundidad del modelo debe limitarse para cumplir el principio de parsimonia.</li></ul> |

### 3.5.7 Artificial Neural Networks (ANN)

*Artificial Neural Networks* (ANN - Redes Neuronales Artificiales, en español), es la herramienta de ML más eficiente y popular, creada con el fin de imitar el cerebro humano: las neuronas están conectadas entre sí, cada neurona se puede modelar como una función de entrada y salida única y la fuerza de cada conexión puede ir variando en el tiempo. Es decir, procesa información a la velocidad de las computadoras, pero con la capacidad de aprender y ajustar sus métodos de procesamiento (Lucey et al., 2019; Rejala et al., 2019a). Se ha demostrado que dan resultados precisos en varios campos de la ingeniería, en el que tratan problemas lineales y no lineales y que no tienen alguna función matemática conocida para modelarlos (W. Wang et al., 2017; Younos et al., 2020). Históricamente se han utilizado en gran medida ANNs con Back-Propagation para desarrollar modelos de deterioro de pavimentos. (Kargah-Ostadi, 2014)

## Estructura

Las ANNs están estructuradas mediante capas que poseen neuronas en su interior; las neuronas cumplen la función de suma neta de los valores que llegan y de activación que se le aplica a la entrada neta. Consta de una capa de entrada, una de salida y la cantidad variable de capas intermedias, dependiendo del problema. Las neuronas de una misma capa están ubicadas verticalmente en línea, los nodos están interconectados entre capas adyacentes, pero nunca de la misma capa, ver FIGURA 10. Cuando todos los nodos están interconectados se denominan capas completamente conectadas. En la capa de entrada estarán los nodos correspondientes a las variables independientes del problema y en la capa de salida los nodos correspondientes al resultado del problema (sea categórico o discreto). Cada neurona tiene un peso respectivo, cuando los datos están normalizados el peso de la capa de entrada determina la influencia que tiene la variable en la salida.






Figura 10: Arquitectura general de una ANN con Back-propagation y Feed-Forward. (Dimitrovic et al., 2018).

Feed-forward es un método de ajuste de pesos de la NN minimizando el error entre la salida real y el objetivo, pasando capa por capa de izquierda a derecha. Feed-Forward permite que las predicciones a largo plazo sean capaces de abordar problemas de sobre-ajuste; volviendo a las ANNs una alternativa más precisa que los modelos estocásticos tradicionales. (Oladele, 2013) Cada una de estas variables se denominan hiper-parámetros.

El aprendizaje de la red es una aproximación estocástica recursiva, iniciando con parámetros con valores aleatorios y ajustándolos hasta que el error entre la salida del modelo y el valor medido sea lo más cercano a cero. Por lo general, una ANN con una capa oculta es suficiente para predecir cualquier valor en una relación no lineal continua; sin embargo, esto no significa que el modelo resultante será el más eficiente o con mayor capacidad de generalización. (Kargah-Ostadi & Stoffels, 2015; Lucey et al., 2019; Rebalá et al., 2019a; Younos et al., 2020).





En la literatura se encuentran distintas “recetas” de modelamiento, Owusu-Ababio, (1998), establece que las capas ocultas tienen un máximo de cuatro veces las variables de entrada en el modelo, lo que resulta un buen punto de partida. Además, que es posible modelar con dos o más capas ocultas, teniendo en consideración que en las primeras capas ocultas siempre debe haber más neuronas que en las capas posteriores. Owusu-Ababio, (1998), primero determina la cantidad óptima de neuronas utilizando sólo una capa oculta y, luego, determina el comportamiento de la red con dos y tres capas ocultas (para el mismo número de neuronas en el paso anterior) y lo compara con el comportamiento de una sola capa oculta. Shafabakhsh et al., (2015), propone un proceso de modelado en el que consideran sólo una capa oculta y, si no hay respuesta aceptable del modelo, se aumenta a dos. Además, establece que el aumento del número de neuronas no necesariamente aumentará la potencia de la red para estimar la relación y predecir con mayor precisión. Georgiou et al., (2018), establece que una red neuronal con una capa oculta es suficiente para resolver problemas de regresión.

### Ventajas y Desventajas

Tabla 10: Ventajas y desventajas de las redes neuronales. (Bianchini & Bandini, 2010; Marcelino et al., 2019; Shafabakhsh et al., 2015; W. Wang et al., 2017)

| VENTAJAS  | DESVENTAJAS   |
|---|---|
| <ul style="list-style-type: none"><li>• Tiene la capacidad de entrenarse en situaciones previas, el cual ajusta los pesos de conexión que permita predecir con precisión, generalizable y calibración automática a nuevos casos.</li><li>• Auto-organiza el mapeo aproximado mediante aprendizaje; por lo tanto, es aplicable dentro de la estructura lógica no identificada.</li><li>• Tiene la capacidad de aprender modelos no lineales y modelos en tiempo real.</li><li>• Puede manejar cambios no importantes en la información de entrada, como datos ruidosos u otros.</li><li>• Capacidad de hacer análisis de secuencias temporales y lógicas.</li><li>• Puede mapear las relaciones complejas entre las variables de entrada y salida, como las del análisis de elementos finitos.</li></ul> | <ul style="list-style-type: none"><li>• Problemas con patrones no observados en pre-procesamiento de datos.</li><li>• No tienen una arquitectura y algoritmo de entrenamiento óptimo. Requiere ajustar varios hiper-parámetros, como el número de neuronas, de capas e interacciones ocultas.</li><li>• Problemas con los mínimos locales en el entrenamiento.</li><li>• Complejo de explicar mecanismos en modelos de predicción.</li><li>• Es susceptible al sobreajuste cuando se tiene una base de datos de entrenamiento pequeña.</li><li>• Una ANN con capas ocultas tiene una función de pérdida no convexa, donde existe más de un mínimo local; por lo tanto, el modelo final dependería de los valores de inicio que se les da a los pesos y podrían generar una precisión de validación diferente.</li><li>• Es sensible al escalado de características.</li></ul> |



## Algoritmos de entrenamiento y convergencia

- **Back-Propagation:** Algoritmo de aprendizaje utilizado principalmente en ANN en conjunto con Feed-Forward para acelerar la convergencia del modelo. Ambos tienen la capacidad de generar modelos de desempeño de pavimentos precisos (Hagan & Menhaj, 1994; Kargah-Ostadi & Stoffels, 2015; Oladele, 2013).
- **Levenberg-Marquardt (LM):** Algoritmo de convergencia simple y estable introducido por Kenneth Levenberg y Donald Marquardt, que representa la forma más común de optimizar pesos y sesgos en ANN. Es una combinación del método de descenso más pronunciado y el algoritmo de Gauss-Newton, que está diseñado para aumentar la eficiencia de los cálculos al excluir la matriz de Hesse. (Hagan & Menhaj, 1994; Karballaezadeh et al., 2020; Shafabakhsh et al., 2015)
- **Scaled Conjugate Gradient (SCG):** Algoritmo de entrenamiento de redes neuronales que estima el tamaño del paso utilizando técnica de búsquedas de líneas, haciéndolo más complejo computacionalmente. Karballaezadeh et al., (2020), hace una modificación al algoritmo reemplazando la técnica de búsqueda de líneas por el mecanismo de escalado de tamaño de paso, lo que acelera el proceso de aprendizaje de la red.

### 3.5.8 Herramientas de Deep Learning

Son algoritmos que agregan capas a la estructura de las ANNs existentes. Son de modelación compleja, sin embargo, existen librerías que ayudan al análisis y desarrollo de estos: Theano, TensorFlow, Torch, Caffe, MXnet, CNTK y Keras. (S. Choi & Do, 2019)

#### Recurrent Neural Network (RNN)

*Recurrent Neural Network* (RNN - Red Neuronal Recurrente en español) herramienta de DL que modifica una red neuronal para que se adapte mejor al procesamiento de datos secuenciales. Tiene la capacidad de memorizar los datos de la capa anterior y manejar datos de series de tiempo. La estructura óptima de un RNN se obtiene probando, iterando y comparando errores entre los modelos. (S. Choi & Do, 2019). Debido a que son tantas variables de entrada y de diferentes escalas, estas deben ser normalizadas para evitar que las variables muy grandes no afecten en el comportamiento del modelo final (Hongren Gong et al., 2018). *Long Short-Term Memory* (LSTM – *Memoria a corto y largo plazo*, en español) es una herramienta complemento que permite que las RNNs sean efectivas para predecir a largo plazo; por lo tanto, es útil cuando se tienen varios datos de series de tiempo. En su estructura tiene una celda de movimiento de memoria ( $C_t$ ) que permite mantener un estado en el tiempo y puertas no lineales que controlan el flujo de datos dentro y fuera de la celda (S. Choi & Do, 2019). Y. Dong et al., (2019), adaptan una ANN con LSTM para poder agregar en el modelo el clima como una variable de serie temporal y ver de mejor manera su impacto en el comportamiento del pavimento.





Tabla 11: Comparación de herramientas de DL, con sus ventajas y desventajas. (S. Choi & Do, 2019; Y. Dong et al., 2019; Hongren Gong et al., 2018; Tabatabaee et al., 2013)

| <b>VENTAJAS</b>  | <b>DESVANTAJAS</b>  |
|--|---|
| <ul style="list-style-type: none"><li>• Genera modelos con muchas variables de entrada.</li><li>• Se adapta mejor al procesamiento de datos secuenciales.</li><li>• Tiene la capacidad de manejar datos en series de tiempo y relaciones no-lineales.</li><li>• LSTM permite predicción efectiva a largo plazo.</li><li>• LSTM también puede ser complemento a herramientas de ML, como ANN y regresión.</li></ul> | <ul style="list-style-type: none"><li>• Requiere datos en series de tiempo.</li></ul> |

### 3.6 Metodología de modelamiento

En esta sección se realiza una breve descripción de los distintos enfoques de modelamiento para la predicción de rendimiento del pavimento.

#### 3.6.1 Enfoques de modelamiento

Según Marcelino et al., (2019), existen dos tipos de enfoques de modelado para la predicción del comportamiento del pavimento: estático y dinámico. Los modelos estáticos no toman en cuenta los valores rezagados de la salida como entradas, lo cual resulta una limitante en la predicción puesto que no considera que los pavimentos se deterioran incrementalmente debido a varios factores, estos son los modelos multi-variables. Los modelos dinámicos pronostican el comportamiento del pavimento utilizando datos históricos de rendimiento del pavimento; esto genera una predicción más precisa, pero a su vez más complicada de obtener, estos son modelos de serie de tiempo. Además, hay modelos que mezclan estos dos enfoques de modelamiento, teniendo variables independientes que están evaluadas durante varios periodos y otras que sólo se tiene su medida en un periodo o un promedio ponderado. En la búsqueda bibliografía se encuentra modelamiento en serie de tiempo, multi-variables y mixto.

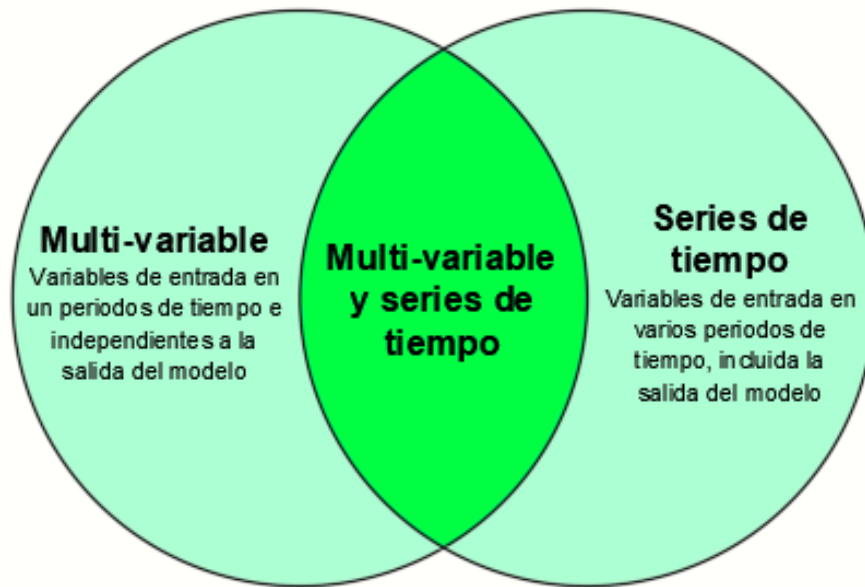


Figura 11: Diagrama de enfoques de modelamiento.

### 3.6.2 Proyección de predicción

La planificación de un sistema de gestión depende de la estimación o predicción, la cual puede ser a corto, mediano y largo plazo. Se considerará a corto plazo cuando la predicción sea desde el momento de la construcción del pavimento hasta los 5 años, mediano cuando es de 5 a 10 años y largo plazo cuando es desde los 10 años en adelante. Dentro de los documentos leídos se tienen de estas tres proyecciones y la predicción completa que abarca toda la vida útil del pavimento, ver FIGURA 12.




Figura 12: Diagrama de proyección de predicción considerada en la clasificación de los documentos en estudio..

Las predicciones a corto plazo son más precisas que a largo plazo, puesto que puede haber cambios en las condiciones locales que en largos períodos de tiempo no están consideradas, como: actividades de mantenimiento y rehabilitación, cambios climáticos, fenómenos estocásticos, cambios en cargas y frecuencia de tránsito, etc. Sin embargo, es importante tener al menos un estimativo de las predicciones a largo plazo, puesto que ayuda a organizarse mejor y optimizar recursos.

### 3.6.3 Nivel de red v/s nivel de proyecto

La gestión de pavimentos se desarrolla en dos niveles de aplicación: nivel de red y proyecto, esto condiciona los datos necesarios para generar los modelos de deterioro. Un sistema de gestión a nivel de red abarca un determinado territorio y permite tomar decisiones que afectan a toda la infraestructura presente, desarrolla un programa de priorización de mantenimiento, rehabilitación y construcción en base a los recursos disponibles, tiempo e influencia; es decir, se enfoca en la estimación de presupuestos para la mantención a nivel macro. Por otro lado, la gestión a nivel de proyecto considera la infraestructura vial presente en un segmento específico de la red vial, evaluando la estructura, funcionalidad y condición presente; por lo tanto, la base de datos requiere más detalle y, por lo general, lo compone segmentos continuos con características en específico. Ambos niveles de gestión coexisten y son complementarios; el resultado a nivel de red pone en contexto al análisis a nivel de proyecto y el resultado a nivel de proyecto verifica el análisis a nivel de red (Ver FIGURA 13). (Pilpe Sarmiento, 2018; Hernan Solminihac et al., 2018).

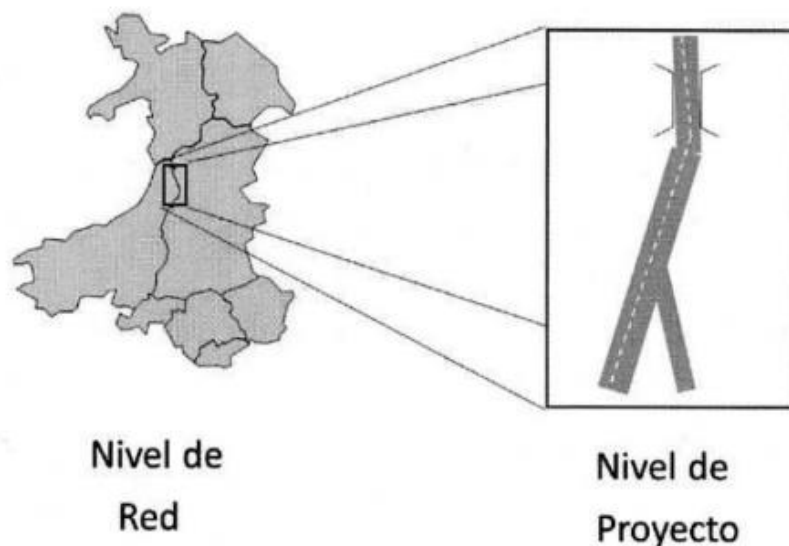




Figura 13: Representación del complemento de proyectos a nivel de red y proyecto. (Hernan Solminihac et al., 2018)

Marcelino et al., (2019), al igual que varios autores, construyen un modelo simple que pueda ser aplicado a nivel de red, por lo que el pre-procesamiento de datos es más superficial y hace menos consideraciones y/o correcciones para tener una base de datos más grande y generalizada. Además, Zhang et al., (2009), establece que la predicción a nivel de red es la clave para tener un buen plan de mantenimiento del pavimento, cuando se tienen modelos de deterioro precisos, lo cual es difícil de obtener cuando se cuenta con muchas variables.



### 3.6.4 Metodología de entrenamiento

#### **Función de activación:**

La relación no lineal entre las variables de entrada y salida del modelo requieren de una relación que es denominada función de activación, utilizada principalmente en ANN. Se tiene la función sigmoidea (ECUACIÓN 4), ReLu, TanH, SoftMax, etc. (Hongren Gong, Sun, Hu, et al., 2019; Hossain et al., 2020; Lucey et al., 2019; Rebala et al., 2019a). La función sigmoidea tiende a saturarse para valores grandes, haciendo que el entrenamiento de la red se vuelva un desafío. Hongren Gong, Sun, Hu, et al., (2019), proponen una modificación de la función sigmoidea, denominada *Exponential Linear Unit* (ELU - Unidad Lineal Exponencial, en español), mostrada a continuación:

$$ELU_{\alpha}(z) = \begin{cases} \alpha[\exp(z) - 1], & z < 0 \\ z, & z > 0 \end{cases} \quad \text{Ecuación 6}$$

Donde  $z$  es la transformación lineal de las variables de entrada (ECUACIÓN 3) y  $\alpha$  es un hiper-parámetro obtenido del pre-procesamiento de la base de datos.



Las funciones también se pueden combinar, tal como lo hacen Hossain et al., (2020), definiendo tres funciones de activación: TANSIG (sigmoidea tangente hiperbólica), LOGSIG (sigmoidea logarítmica) y PURELIN (función lineal pura). No hay una función de activación óptima, todas permitirán llegar al resultado; sin embargo, mediante iteración se podrá saber la función que permite que el modelo converja al resultado en menor tiempo.

### 3.6.5 Optimización de modelos

Los algoritmos de optimización ayudan a los modelos a resolver problemas con mayor eficiencia. A continuación, se encuentran los algoritmos de optimización presentes dentro de la literatura revisada, la mayoría usados para generar los modelos híbridos:

#### **Adaptive Moment Estimation (Adam):**

*Adaptive Moment Estimation* (Adam – Estimación Del Momento Adaptativo, en español) es un algoritmo de optimización eficiente que ajusta la tasa de aprendizaje adaptativa y determina la solución óptima de manera automática. Es práctico cuando se tienen problemas estocásticos y con variables de altas dimensión. Adam recomienda una tasa de aprendizaje predeterminada de 0,001. (Hongren Gong, Sun, Hu, et al., 2019; Kingma & Ba, 2017)



### **Adaptive Neuro-Fuzzy Inference System (ANFIS):**

*Adaptive Neuro-Fuzzy Inference System* (ANFIS - Sistema Adaptativo de Interferencia Difusa, en español es un sistema de optimización que modela un conjunto de salidas, con incertidumbre y conceptos del lenguaje natural, a partir de un número seleccionado de entradas utilizando funciones de pertenencia específicas, operaciones lógicas y reglas de si-entonces. En la lógica difusa, toda información no es completamente verdadera o falsa, están asociados a porcentajes de severidad. Los modelos ANFIS resultantes son complejos de comprender debido a las funciones de pertenencia y las reglas de si-entonces (Bianchini & Bandini, 2010; S. Dong et al., 2019; M. Mazari & Rodriguez, 2016).

### **Firefly Algorithm (FA):**

*Firefly Algorithm* (FA - Algoritmo de Luciérnagas, en español), algoritmo de optimización desarrollado por Yang que resuelve problemas de optimización basados en los patrones de parpadeo y comportamiento de las luciérnagas (Nguyen et al., 2019). Está basado en tres reglas:



- Las luciérnagas son unisex, por lo que se sienten atraídas por las demás independiente de su sexo.
- El atractivo de una luciérnaga es proporcional a su brillo, la cual se mueve sin dirección definida ya que no hay ninguna luciérnaga más brillante cerca.
- El brillo de cada luciérnaga estaría definido por el valor de su función objetivo.

### **Imperialist Competitive Algorithm (ICA):**

*Imperialist Competitive Algorithm* (ICA - Algoritmo de Competencia Imperialista, en español), algoritmo inspirado en la rivalidad colonial que representa un algoritmo evolutivo de optimización. El algoritmo comienza con una población inicial (países), los cuales se dividen en dos categorías: estados imperialistas y colonias. Los países con el imperio o colonia más fuertes irán triunfando y los más débiles irán colapsando. El movimiento de las colonias contra los imperialistas, la rivalidad de los imperialistas y el mecanismo de disolución continúan hasta que todos los países se fusionan en un solo estado con un solo imperio mientras otros sirven como sus colonias, luego el algoritmo finaliza. (Karbalaeezadeh et al., 2020)

### **Particle Swarm Optimization (PSO):**

*Particle Swarm Optimization* (PSO - Optimización de Enjambre de Partículas, en español) es una técnica de evolución de algoritmo fácil de aplicar y de convergencia rápida. Se aplica con éxito en la optimización de funciones y parámetros, control de sistemas, etc. Yan & Zhang, (2011), establecen los parámetros claves que afectan el algoritmo mediante PSO: parámetro de equilibrio  $c$ , parámetros insensibles y parámetro de función de Kernel en SVM, así evita que los parámetros sean determinados subjetivamente.



## Fruit Fly Optimization Algorithm (FOA)

*Fruit Fly Optimization Algorithm* (FOA - Algoritmo de Optimización de la Mosca de la Fruta, en español), algoritmo de optimización inspirado en la búsqueda de alimentos del insecto *Drosophila*, un tipo de mosca de la fruta que tiene un olfato y una vista superior a otros insectos. Las moscas de la fruta siguen el olor de las fuentes de alimento dispersas por el aire y se dirigen hacia él. Al acercarse a la fuente de alimento, la mosca de la fruta observa para localizar la comida y otras moscas de la fruta. (Nabipour et al., 2019)

### 3.6.6 Criterios de Evaluación

Los modelos deben evaluarse cuantitativamente y cualitativamente, basándose en la precisión de la predicción y capacidad de generalización (Kargah-Ostadi & Stoffels, 2015).

#### 3.6.6.1 Errores

##### Mean Squared Error

*Mean Squared Error* (MSE - Error Cuadrático Medio, en español) mide la diferencia cuadrática media entre los valores estimados y el valor real (ver ECUACIÓN 7). Mientras más cercano a 0 sea, el modelo será más preciso, efectivo y tendrá mejor desempeño. (Kargah-Ostadi & Stoffels, 2015).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{Ecuación 7}$$



Donde  $n$  es el número de predicciones generadas,  $y$  son las variables observadas o evaluadas e  $\hat{y}$  es el valor de predicción del modelo.

Para evaluar modelos por lo general se determina el MSE, el promedio (AVG MSE) y la desviación estándar (STD MSE). También se adopta la raíz de MSE (RMSE, Root Mean Squared Error), que es una medida de precisión sensible a valores atípicos con las mismas unidades de los valores que se quieren comparar, cumple las mismas condiciones de precisión que MSE.

Karballaezadeh et al., (2019), utiliza la métrica llamada eficiencia de Nash-Sutcliffe (NSE), el cual se obtiene sustrayendo a 1 la división de MSE y la varianza (ver ECUACIÓN 8)

$$NSE = 1 - \frac{MSE}{\sigma^2} \quad \text{Ecuación 8}$$

Donde,  $\sigma$  es la desviación estándar de los datos evaluados.



## Mean Absolute Error

*Mean Absolute Error* (MAE - Error Absoluto Medio, en español) es una función que cuantifica la precisión de la predicción del modelo, resistente a la influencia de valores atípicos. Usa la misma escala que lo datos a comparar. Se calcula con la siguiente ecuación (Hongren Gong, Sun, Hu, et al., 2019; W. Wang et al., 2017):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \text{Ecuación 9}$$

Donde  $n$  es el número de predicciones generadas,  $y$  son las variables observadas o evaluadas e  $\hat{y}$  es el valor de predicción del modelo. MAE es conceptualmente más simple e interpretable que RMSE, no requiere funciones cuadráticas ni raíz cuadrada, es simplemente la distancia absoluta promedio. RMSE es más susceptible a errores que MAE.

*Mean Absolute Percentage Error* (MAPE, Error del Porcentaje Absoluto Medio) es una adaptación porcentual de MAE, obtenida al dividir la ECUACIÓN 9 por el valor absoluto de la  $i$ -ésima variable observada ( $y_i$ ) (Hossain et al., 2020).

Se tiene la siguiente escala de precisión:



1. Alta precisión:  $MAPE < 0,1$
2. Buena precisión:  $0,1 < MAPE < 0,2$
3. Precisión razonable:  $0,2 < MAPE < 0,5$
4. Mala precisión:  $MAPE > 0,5$

## Coefficiente de determinación ( $R^2$ )

Es una de las mediciones más comunes para la evaluación de modelos de predicción. Se grafican los resultados del modelo entrenado y los datos de prueba y se obtiene el coeficiente de determinación ( $R^2$ ) según la ECUACIÓN 10.

$$R^2 = 1 - \frac{\sum_{i=0}^{n_{samples}-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{n_{samples}-1} (y_i - \bar{y})^2} \quad \text{Ecuación 10}$$

Donde,  $\hat{y}_i$  es el valor predicho de la  $i$ th muestra,  $y_i$  es el valor real de la  $i$ th muestra y  $\bar{y}$  es el promedio de los valores reales. Mientras más cercano sea  $R^2$  a 1, mayor será la capacidad predictiva del modelo (Kargah-Ostadi & Stoffels, 2015; Marcelino et al., 2020).



## Coefficiente de correlación de Pearson ( $r$ )

Medida de dependencia lineal entre dos variables cuantitativas y continuas. Es un indicador estándar de calidad independiente de la escala de las variables, que varía entre  $-1$  y  $1$ . (Karballeezadeh et al., 2019). Tiene cuatro posibles casos:

- $r = 1$ : Relación completa y positiva, indica relación directa.
- $0 < r < 1$ : Relación incompleta y positiva.
- $r = 0$ : No hay relación lineal entre las variables, pero no son necesariamente independientes.
- $r = -1$ : Relación completa y negativa, indica relación inversa.
- $-1 < r < 0$ : Relación es incompleta y negativa.

Mientras el valor absoluto de  $r$  sea más cercano a uno, mayor será la relación entre las variables.

## Matriz de confusión



La matriz de confusión es un método usado para medir el desempeño de un clasificador binario en aprendizaje supervisado, ver TABLA 12. Tal como su nombre lo dice, es útil cuando se quiere tener noción de la confusión que está experimentando un modelo (Elbagalati et al., 2018). También existen matrices de confusión multiclase, pero no serán abordados en este documento. Para hacer el análisis se consideran cuatro categorías dadas por las relaciones entre el valor objetivo y el predicho, determinados cada vez que se quiere evaluar un modelo.

Tabla 12: Matriz de confusión para problemas de clasificación binarios.

|                |          | Predicción del Modelo   |                         |
|----------------|----------|-------------------------|-------------------------|
|                |          | Positivo                | Negativo                |
| Valor objetivo | Positivo | Verdadero Positivo (VP) | Falso Negativo (FN)     |
|                | Negativo | Falso Positivo (FP)     | Verdadero Negativo (VN) |

Donde:

- VP: Cantidad de positivos que fueron clasificados correctamente como positivos por el modelo.
- VN: Cantidad de negativos que fueron clasificados correctamente como negativos por el modelo.
- FN: Cantidad de positivos que fueron clasificados incorrectamente como negativos por el modelo.
- FP: Cantidad de negativos que fueron clasificados incorrectamente como positivos por el modelo.



La construcción de la matriz de confusión permite obtener un indicador de precisión (ECUACIÓN 11), sensibilidad (ECUACIÓN 12) y F1-Score (ECUACIÓN 13). La precisión representa el porcentaje de predicciones positivas determinadas correctamente, es sesgada cuando se cuenta con un set de datos en que la mayoría pertenece a una clase. La sensibilidad representa el porcentaje que logra clasificar correctamente cuando la clase es positiva; cuando las clases de datos son equilibradas existe una compensación entre la precisión y sensibilidad del modelo. *F1 – Score* es un índice que combina la precisión y sensibilidad en un solo número, es un buen indicador para resumir la evaluación del modelo.

$$P = \frac{VP}{VP + FN} \quad \text{Ecuación 11}$$

$$S = \frac{VP}{VP + FP} \quad \text{Ecuación 12}$$



$$F1 - Score = \frac{2(P \cdot S)}{P + S} \quad \text{Ecuación 13}$$

### Validación cruzada

La validación cruzada de *K-Fold* es una técnica de evaluación de algoritmos de aprendizaje dividiendo el conjunto de entrenamiento en K segmentos. Primero se usarán los datos del primer segmento para validar el modelo y los restantes (K-1) para entrenarlos, luego se continuará validando el modelo con el segundo segmento y así sucesivamente hasta que se hayan usado todos los segmentos. Se debe hacer un uso adecuado de la validación cruzada en todos los pasos del algoritmo para asegurar la generalización y proporcionar una estimación casi imparcial del verdadero error del modelo (Marcelino et al., 2019; Rebala et al., 2019a). La validación cruzada es óptima para determinar la cantidad de kernels óptima para modelar los datos en SVM. En el caso de RF se determina internamente, en cada uno de los conjuntos que se dejan para validación al depurar los árboles (Rebala et al., 2019a).

#### 3.6.7 Marco de comparación de modelos

Los modelos se deben comparar en relación a otros de referencia, los cuales pueden ya estar desarrollados dentro de la literatura o desarrollados dentro del mismo estudio, pero con una herramienta de modelación distinta (Marcelino et al., 2019). Para que la comparación sea completa, se deben evaluar los procesos de aprendizaje y los modelos desarrollados en función de efectividad (comparación de errores), eficiencia (tiempo de procesamiento) y confiabilidad. Finalmente el modelo más óptimo será el que tenga menor MSE, mayor poder de generalización y parsimonia (modelo más simple y con igual error) (Kargah-Ostadi & Stoffels, 2015).



La mayoría de las aplicaciones de ML carecen de un enfoque sistemático para la parametrización robusta de los algoritmos, la mayoría de los modelos están desarrollados basándose sólo en la precisión de predicción y, en algunos casos, determina la capacidad de generalización. Es decir, hay carencia de evaluación cualitativa del comportamiento de los modelos en relación a los principios de la ingeniería de pavimentos. (Kargah-Ostadi & Stoffels, 2015)

### 3.6.8 Análisis de sensibilidad:

Proceso de selección de variables de entrada independientes más influyentes en la variable de salida del modelo. Es un paso importante cuando se tiene un modelo con múltiples entradas. En la literatura se encuentran distintos métodos para obtenerlo:



Método 1: Probar valores aleatorios dentro del rango de cada variable de entrada y comparándolo con la salida correspondiente. Las variables que tengan mayor desviación serán las variables más sensibles. Este método sirve para evaluar la importancia de cada variable en un contexto lineal y no lineal. (Lucey et al., 2019).

Método 2: Eliminar un tipo de variable a la vez, viendo su influencia en el modelo final. El modelo no será sensible a la variable eliminada si se tiene la misma distribución que en el modelo original. (Marcelino et al., 2019). RF determina automáticamente la importancia de las variables independientes, puesto que las ordena con respecto a su importancia al ver la interacción que tiene cada variable de entrada y la disminución en la impureza. Cuando una variable sea importante, la predicción no reducirá su precisión si es que esta se reordena (Rebala et al., 2019a).

El método *Grey Relation Analysis* (GRA - Análisis de Relaciones Grises, en español) refleja cuantitativamente la relación entre la salida del modelo y las variables de entrada, por lo que puede encontrar los factores principales del modelo. El método genera curvas para cada variable que depende de sus datos estadístico. Mientras más cerca esté cada factor con la variable dependiente, mayor relación tendrán. (X. Wang et al., 2020). Hossain et al., (2020), determinan un índice de sensibilidad mediante la ECUACIÓN 14:



$$S = \left( \frac{O_2 - O_1}{I_2 - I_1} \right) \left( \frac{I_{ave}}{O_{ave}} \right) \quad \text{Ecuación 14}$$

Donde,  $I_1$  e  $I_2$  son los valores de entrada más grandes y pequeños respectivamente,  $O_1$  y  $O_2$  son los valores de salida correspondientes a  $I_1$  e  $I_2$  respectivamente y  $I_{ave}$  y  $O_{ave}$  son los valores promedios de  $I_1$  e  $I_2$  y  $O_1$  y  $O_2$ , respectivamente. Mientras más grande sea el valor de  $|S|$ , mayor influencia tendrá la variable dentro del modelo.



---

Fathi et al., (2019), realizan un análisis de sensibilidad del Método 2 al modelo híbrido desarrollado. El análisis muestra que el modelo es sensible a la edad, contenido asfáltico y vacío en los agregados minerales. Por otro lado, Lucey et al., (2019), realiza un análisis de sensibilidad del Método 1 para predecir IRI, resultando la edad la variable más influyente, seguido de ESAL y SN.



## CAPÍTULO 4. ANÁLISIS ESTADÍSTICO Y COMPARACIÓN DE HERRAMIENTAS DE MACHINE LEARNING APLICADO A MODELOS DE COMPORTAMIENTO

### 4.1 Metodología de búsqueda

Esta investigación revisa los documentos relacionados con las aplicaciones de ML en modelos de deterioro, hasta diciembre del 2020. Para esto se hace una búsqueda en Scopus, pues es la mayor base de datos de citas y resúmenes de bibliografía en campos de la ciencia, tecnología, medicina, ciencias sociales y las artes y humanidades. Cuenta con herramientas de búsqueda inteligente para ayudar a la investigación dentro de un universo de 24.600 artículos y 5.000 autores, aproximadamente. Se realiza una búsqueda en inglés, combinando palabras de los tres conjuntos presentes en la TABLA 13, limitando a artículos de 1990 al 2020.

Tabla 13: Combinación de palabras claves en Scopus para obtener pesquisa completa..

|                                | <b>PALABRAS CLAVES</b>   |
|--------------------------------|--|
| <b>Herramientas de ML</b>      | Machine Learning, Artificial Intelligence, Neural Network, Support Vector Machine, Genetic Programming, Decision Tree, Random Forest, Support Vector Regression. |
| <b>Modelos de predicción</b>   | Prediction Model, Time series, Prediction, Progression, Pavement prediction, Model, Regression.  |
| <b>Desempeño de pavimentos</b> | Pavement Performance, Pavement Condition, International Roughness Index, Pavement, Crack Condition, Crack, Pavement Roughness, Pavement Maintenance, PMS.        |

En total se encuentran 235 documentos; luego se lee el resumen de cada uno y se filtran sólo los de interés: *Machine Learning aplicado a modelos de deterioro*. En total resultan 101 documentos que sirven, los cuales son leídos a fondo y se clasifica la información en una tabla resumen en Excel con lo siguiente (ver TABLA 14):

Tabla 14: Información clasificada de cada documento leído.

| N° | Título | Autor  | Año          | Journal, Congress, symposium, etc. | DOI                      | Objetivos | Herramienta ML | Modelamiento | Origen Base de Datos |                              |
|----|--------|--------|--------------|------------------------------------|--------------------------|-----------|----------------|--------------|----------------------|------------------------------|
| →  | Input  | Output | Arquitectura | Función de Transferencia           | Algoritmo de Aprendizaje | % Train   | % Valid        | % Test       | Resultados           | Observaciones y Conclusiones |

## 4.2 Resultados

Los documentos clasificados se enumeran del 1 al 101, tal como en la TABLA 15, para simplificar las referencias dentro de los resultados a continuación.

Tabla 15: Extracto de tabla en ANEXO A, con el fin de simplificar referencias en resumen de resultados.

| N°  | TÍTULO   | AUTOR   | AÑO  | REFERENCIA                 |
|-----|--|---|------|----------------------------|
| 1   | Transfer learning for pavement performance prediction  | Marcelino, de Lurdes Antunes, Fortunato, Gomes. | 2020 | (Marcelino et al., 2020)   |
| .   |  |   |      |                            |
| .   |  |   |      |                            |
| .   |  |   |      |                            |
| .   |  |   |      |                            |
| 101 | A model based on artificial neural networks and genetic algorithms for pavement maintenance management | Bosurgi, Trifirò.                               | 2005 | (Bosurgi & Trifirò, 2005a) |

### 4.2.1 Base de datos

Los documentos, revisados, en su mayoría emplean bases de datos del programa de investigación LTPP (ver GRÁFICO 2), puesto que contienen información completa y disponible públicamente acerca de los materiales de los pavimentos, condiciones ambientales, volúmenes de tránsito, historial de mantenimiento y rehabilitación, entre otros. Lo que posibilita que investigadores de todo mundo puedan generar modelos de comportamiento de pavimentos considerando una gran cantidad de variables de entrada.






Gráfico 2: Base de datos presentes en los documentos leídos y clasificados se Scopus.



A continuación, se presentan algunos estudios donde se usaron fuentes públicas, datos de laboratorio, datos recopilados y datos sintéticos.

### **LTPP:**

Para modelar con ML se requiere una base de datos robusta y completa, en especial cuando se modela una ANN, lo cual se obtiene con LTPP de manera libre y confiable. Razón por la cual hay varias organizaciones que administran sus recursos mediante modelos empíricos-mecanicistas determinados con la base de datos de LTPP, lo que significa un buen punto de comparación para los modelos de ML desarrollados a partir de estos. Además, contiene de todos los tipos de pavimentos sometidos a distintas condiciones estructurales, solicitaciones climáticas, solicitaciones de tránsito, modos de construcción y estrategias de mantenimiento y rehabilitación.

Hongren Gong et al., (2018), usa datos de LTPP para comparar modelos de predicción de ahuellamiento, mediante RNN, MLR y la función de transferencia de MEPDG, que se determina con los mismos datos de LTPP para su calibración. RNN obtiene mejores resultados que los modelos con regresión y la función de MEPDG, superándolos en más del 90% en precisión de predicción. Fathi et al., (2019), extrae un conjunto de datos de LTPP recopilados durante 20 años (1995-2016) en EE.UU comprendidos en cuatro zonas climáticas: congelación seca, sin congelación seca, congelación húmeda y sin congelación húmeda.

Marcelino et al. (2019) y Younos et al. (2020) utilizan datos recopilados de LTPP publicados el 31 de Julio del 2017. Marcelino et al. sólo considera datos con menos del 30% de datos faltantes, donde el 80% del total es para entrenamiento y el resto para validación. Younos et al., (2020), usa 89 secciones, incluidas 617 observaciones de SPS-1, de pavimentos flexibles convencionales con capa/s de hormigón asfáltico.

S. M. Pirayonesi & El-Diraby, (2020), usan datos de LTPP para predecir PCI en el corto y mediano plazo con variables de entrada que estén disponibles gratuitamente en las bases de datos de los departamentos de transporte, significando un aporte a los municipios más pequeños y con menos recursos.

Abdelaziz et al., (2020) y Ziari, Maghrebi, et al., (2016), usan datos de LTPP para predecir el IRI en pavimentos flexibles y con tratamientos de mejora. Ziari, Maghrebi, et al., (2016), limita su estudio con umbrales máximos de tránsito promedio anual e índice de congelación. Abdelaziz et al., (2020), utiliza pavimentos flexibles (GPS-1, GPS-2 y GPS-6) y pavimentos con mejora (SPS-1, SPS-3 y SPS-5). En total se tiene una base de datos con 2439 evaluaciones, los IRI inicial para los pavimentos sin tratamiento deben ser determinados manualmente ya que LTPP no lo incluye en las secciones GPS. El modelo se desarrolla con ANN y regresión lineal múltiple, obteniendo resultados mucho mejores con ANN ( $R^2 = 0,75$ ) de arquitectura 5-10-10-10-1 con LOGSIG como función de transferencia.

## Laboratorio

Los datos de laboratorio ocupan un 8% del total de las bases de datos presentes en estudios, puesto que requieren más tiempo y mayor inversión, por lo que es recomendado para estudios a corto plazo y más específicos. Heidari et al., (2018), forman su propio inventario para generar un modelo de predicción de ahuellamiento y baches. El inventario cuenta con 50 [km] de carreteras primarias y secundarias evaluadas entre oct-nov de 2014, en total son 185 segmentos. La base de datos cuenta con valores discretos y continuos, tomados mediante inspección visual por expertos. El departamento de transporte de Minnesota tiene una pista de prueba de pavimentos compuesta de distintos materiales y estructuras sometida a diferentes volúmenes de tránsito que es monitoreada mediante sensores que registran datos de evaluación. (Tabatabaee et al., 2013)

## Departamento de Transporte

Dentro de la base de datos proveniente de Departamento de Transportes, los que más se repiten son KDOT y FDOT (ver GRÁFICO 3). A continuación, se presentan algunos estudios correspondientes a esta sección.






Gráfico 3: Bases de datos provenientes de Departamento de Transporte



ConnDOT: Owusu-Ababio, (1998), modela el agrietamiento con ANNs a partir de datos de ConnDOT probando distintas arquitecturas de una red, primero se determinan las neuronas necesarias en la capa oculta y luego se distribuyen estas neuronas en dos y tres capas ocultas y se hace la comparación con una sola capa. Selecciona 60 observaciones de pavimentos flexibles con % de agrietamiento, edad de la superficie del pavimento, espesor y ESAL. La base de datos se divide en dos subconjuntos, 75% para entrenamiento y 25% para validación de la red.


FDOT: Jidong Yang et al., (2003), proponen un modelo alternativo al de FDOT para predecir PCR mediante modelos ANNs y auto-regresivos (AR) para pavimentos flexibles y rígidos, utilizando datos históricos de los últimos 5 años. Luego, en 2006 generan modelos de predicción de agrietamiento en pavimentos flexibles modelado con ANN y cadenas de Markov recurrentes, utilizando datos de FDOT.

KDOT: Roberts & Attoh-Okine, (1998), generan modelos de predicción de rugosidad usando dos técnicas de ANNs con una base de datos extraída del SGP del KDOT, con varias características del estado del pavimento y solicitudes de tránsito. Si bien los  $R^2$  no alcanzan a pasar el 0,8, el estudio resulta un buen punto de partida para los modelos de predicción de rugosidad con herramientas de ML.

ODOT: Eldin & Senouci, (1995a, 1995b), predicen PCR en pavimento rígido (a) y flexible (b) utilizando índices de agrietamiento y ahuellamiento presentes en la base de datos del ODOT, mediante una ANN. ANN muestra una buena capacidad de generalización tanto para pavimentos rígidos como para pavimento flexibles ( $MAE_a = 0,022$ ,  $MAE_b = 0,023$ ), con alta tolerancia a datos ruidosos e incompletos (nivel de confianza del 95%).

### **Datos recopilados y/o medidos:**

Dentro de la base de datos obtenida de datos recopilados o medidos, la mayoría se desarrolla en China e Irán (ver GRÁFICO 4). China ha tenido un avance económico que ha crecido exponencialmente desde 1949, avanzando en maquinarias, equipos, estructuras, educación, medicina e investigación científica, teniendo una proyección a largo plazo en proyectos de inversión. El Gobierno Chino ofrece políticas preferenciales e incentivos financieros generosos para empresas emergentes en IA, lo que ha motivado a varias empresas a innovar. Galindo, (2021), proyecta que China dominará la IA en 2030 en su artículo de en la revista “*Muy Interesante*”.



Irán también ha tenido un aumento significativo en publicaciones científicas desde 1996 hasta la fecha, lo que implica incremento y mejora en la calidad de la base de datos; esto queda plasmado en el informe del 2016 de la United Nations Conference on Trade and Development (UNCTAD, Conferencia de las Naciones Unidas sobre Comercio y Desarrollo en español) dando énfasis al desarrollo de producción científica a largo plazo. Se describe a la economía iraní como sólida, diversificada, autosuficiente y eficiente, posicionándola dentro de las economías más innovadoras a nivel mundial. Además, Irán debe ingeniárselas en su desarrollo económico y geopolítico debido al aislamiento internacional producido por la mala reputación histórica del país (Pevarello, 2017).

En resumen, China motiva a la investigación con IA invirtiendo gran parte de su capital, proyectándose a ser pionero en 2030 y, por otro lado, Irán se ve en la obligación de innovar generando su propio inventario conciso disponible para avances en IA, ya que por su mala reputación no tiene acceso a las bases de datos dispuestas en los otros países.






Gráfico 4: Datos recopilados y/o medidos.

Yan & Zhang, (2011), recopilan 33 conjuntos de datos de una carretera asfáltica en el Este de China para predecir PCI. Yao et al., (2019), recopilan información de los últimos veinte años de once autopistas en Jiangsu, China, obtenida del sistema de gestión del país, para predecir 5 condiciones de pavimentos flexibles y con mejoras, mediante ANN. Esta información incluye datos básicos, información de tránsito, mantenimiento y registros históricos de deterioros de los pavimentos.



Shahnazari et al., (2012), usan datos de evaluaciones de PCI de más de 1.250 [km] de carreteras en Irán para predecir PCI mediante ANN y GP. Gupta et al., (2011), recopilan datos de 18 secciones de pavimentos de bajo volumen durante dos años continuos, pertenecientes a Uttarakhand y Uttar Pradesh, India. Con ANNs y análisis estadísticos generan un modelo de predicción del Maintenance Priority Index (MPI, Índice de Prioridad de Mantenimiento).

Wang et al., (2017), utiliza datos reales de 9 secciones con 143 registros utilizado por la autopista interestatal de pavimento rígido de EE.UU con características de diseño, tránsito y ambientales, para probar predicción de falla en juntas, en modelos ya existentes de regresión no lineal multi-variable, ANN y Cadena de Markov. Hongren Gong, Sun, Hu, et al (Hongren Gong, Sun, & Huang, 2019; Hongren Gong, Sun, Hu, et al., 2019) tienen dos estudios en los que predicen el agrietamiento utilizando la base de datos extraída del proyecto NCHRP 01-37A. En un documento modelan el agrietamiento con DT y RF, y en el otro, modelan con ANN.



#### Datos sintéticos:

Cerca del 8% de los documentos leídos utilizan una base de datos sintética, la mayoría hace una predicción que abarca toda la vida útil del pavimento. Si bien es práctico usar una base de datos sintética, ya que no requiere tiempo ni inversión en la toma de datos, los modelos requieren una prueba con datos reales para que puedan ser aplicables por los SGP. Por lo tanto, los datos sintéticos son una buena alternativa para entrenar y validar los modelos, pero requieren datos reales para probarlos. La TABLA 16 presenta los documentos con base de datos sintética y el software que usan para generarla.

Tabla 16: Documentos base de datos sintéticos con su fuente respectiva.

|                         | FUENTE                                 | REFERENCIA                                |
|-------------------------|--|---|
| <b>Datos sintéticos</b> | ABAQUS                                 | (Shafabakhsh et al., 2015)                |
|                         | Combinación de patrones de tratamiento | (Hafez et al., 2019)                      |
|                         | Datos adaptados de Washington          | (Lea et al., 2014)                        |
|                         | Elementos Finitos                      | (Ceylan et al., 2011; M. Li & Wang, 2018) |
|                         | FEAFAA                                 | (Kaya et al., 2018)                       |
|                         | HDM-III + RODEMAN                      | (Attoh-Okine, 2001)                       |
| HDM                     | (Attoh-Okine, 2005)                    |   |

Halil Ceylan et al., (2011), utiliza datos sintéticos para predecir SIF obtenida de 100.000 corridas de un programa de elementos finitos, con datos de longitudes de grietas y estructuras de pavimentos. M. Li & Wang, (2018) utiliza datos sintéticos para predecir el esfuerzo en pavimento asfáltico mediante modelo ANN-GP híbrido. La base de datos proviene de la simulación de la prueba *Falling Weight Deflectometer* (FWD - Deflectómetro de Caída de Peso, en español) que considera propiedades visco-elásticas de la capa asfáltica y la no linealidad de las capas libres.



Shafabakhsh et al., (2015), genera un modelo de predicción de deformaciones longitudinales en el fondo de la capa asfáltica de pavimentos flexibles sometidos a cargas en movimiento mediante ANNs con Back-Propagation para reducción de errores y LM. Para entrenar la red se usan datos sintéticos de deformaciones mediante el modelo de elementos finito ABAQUS y luego se valida la red con una pista de prueba de la Universidad de Penn State. En total son 350 conjuntos de datos con propiedades estructurales, cargas de tránsito y deformaciones del pavimento. Los resultados indican que una ANN con estructura 7-13-1 es apropiada para predecir deformaciones con alta precisión y que, además, puede reducir el tiempo de cálculo, convirtiéndola en una herramienta importante para predecir la respuesta del pavimento.

### Datos compuestos:

Aproximadamente el 5% de los documentos usan una base de datos compuesta, lo que se da, en general, en casos en los que el inventario de un lugar en particular no es suficiente para generar el modelo. El uso de datos compuesto permite generar predicciones durante toda la vida útil del pavimento, teniendo estudios más precisos a corto plazo y que brindan la capacidad de mayor proyección de inversión. La TABLA 17 presenta los estudios con base de datos compuesta y su fuente.

Tabla 17: Documentos con base de datos compuesta y su fuente de obtención.

|                                | FUENTE                             | REFERENCIA                     |
|--------------------------------|------------------------------------|--------------------------------|
| <b>Base de datos Compuesta</b> | FWD + Datos recopilados            | (Whiteley-Lagace et al., 2011) |
|                                | Insp. Visual (Ibadan) + IRI Kaduna | (Abiola et al., 2012)          |
|                                | LTPP + Datos Portugal              | (Marcelino et al., 2020)       |
|                                | LTPP + Datos sintéticos            | (Hossain et al., 2019, 2020)   |

Marcelino et al., (2020), propone un modelo de predicción de IRI enfocado en aprendizaje por transferencia; utilizando datos de la red de carretera portuguesa y transfiriendo el conocimiento de una base de datos con las mismas condiciones de LTPP. Es decir, los datos de entrenamiento son de la base de LTPP y los de validación son de la carretera portuguesa. Además, utilizó una versión adaptada del algoritmo TrAdaBoost para poder utilizarlo en problemas de regresión.

#### 4.2.1.1 Sub-conjuntos de base de datos

La mayoría de los modelos se obtienen dividiendo la base de datos en subconjuntos de entrenamiento, validación y prueba. Con los datos de entrenamiento y validación se obtiene el algoritmo del modelo final, los datos de prueba son nuevos datos que se usan para ver la factibilidad de aplicar el modelo en un SGP de alguna agencia en particular. La mayoría de los modelos tienen un sub-conjunto de entrenamiento, pero no todos tienen de validación y prueba, además, algunos generan el modelo mediante Cross-Validation.

El GRÁFICO 5 presenta los documentos que dividen la base de datos en sub-conjuntos de entrenamiento, validación y testeo, según herramientas de ML, generado a partir de la TABLA 26 en Anexo.






Gráfico 5: División base de datos en sub-conjuntos de entrenamiento, validación y testeo, para las herramientas de ML.

Los modelos de ANN, SVM, GP, híbrido y regresión tienen una relación pareja entre la división de la base de datos. En especial son modelos que hacen una diferencia entre los subconjuntos de entrenamiento, validación y prueba, lo que puede ser debido a que son documentos que generan los modelos con una base de datos amplia.

RF, DT, KNN y Naïve Bayes sólo dividen la base de datos en dos subconjuntos, ya que son herramientas que no se actualizan automáticamente, por lo tanto, se usan principalmente para generar algoritmos y compararlos, en vez de proyectarlos a su aplicación en modelos de deterioro. RNN también divide la base en dos subconjuntos, principalmente porque requiere que el subconjunto de entrenamiento sea muy grande, por lo tanto, al dividir la base de datos en menos subconjuntos es posible.

El-Diraby & Pirayonesi, (2019), M. Pirayonesi & El-Diraby, (2017) y Ziari, Maghrebi, et al., (2016), generan el algoritmo del modelo mediante Cross-Validation. Ziari, Maghrebi, et al., (2016), genera 10 subconjuntos para entrenar y validar el modelo SVM mediante MAE, RMSE y R. El-Diraby & Pirayonesi, (2019; 2017), generan modelos de predicción de PCI a corto y mediano plazo entrenándolos con Cross-Validation de diez veces y luego los prueba con datos reales de caminos en Ontario.



#### 4.2.2 Variables de entrada

Los modelos de deterioro determinan un índice de condición que depende de diferentes variables, las cuales deben estar presentes en la base de datos para generar el modelo. Es por esto que es importante modelar con variables que sean fáciles de obtener y que, de preferencia, tengan una evaluación que se repita periódicamente. A continuación, se presentan la TABLA 18 con las variables de entrada más habituales en las investigaciones leídas para los modelos de deterioro.

Tabla 18: Variables de entrada más utilizadas en modelos de deterioro, según categoría.

| Categoría  | Variables de entrada                           | Abreviatura | Cualidad de la variable |
|--|--|-------------|-------------------------|
| <b>Propiedades estructurales</b>                   | Espesor del pavimento                          | PT          | Ordinal                 |
|  | Material del pavimento                         | PM          | Nominal                 |
|  | Edad del pavimento (desde construcción)        | AGE         | Ordinal                 |
|  | Clase funcional del camino                     | FUNC_CLASS  | Nominal                 |
|  | Número Estructural                             | SN          | Ordinal                 |
| <b>Condiciones climáticas</b>                      | Precipitación anual                            | AP          | Ordinal                 |
|  | Temperatura promedio                           | AT          | Ordinal                 |
|  | Región climática                               | CR          | Nominal                 |
|  | Índice de Congelamiento                        | FI          | Ordinal                 |
| <b>Condiciones de tránsito</b>                     | Carga eqq. por eje estándar                    | ESAL        | Ordinal o escalar       |
|  | Vol. de tránsito diario                        | ADT         | Ordinal o escalar       |
|  | Vol. de tránsito de camiones                   | DTT         | Ordinal o escalar       |
| <b>Condiciones y método de construcción</b>        | Agrietamiento                                  | CRACK       | Ordinal o escalar       |
|  | Ahuellamiento                                  | RUT         | Ordinal o escalar       |
|  | Rugosidad                                      | IRI         | Ordinal                 |
| <b>Historial de mantenimiento y rehabilitación</b> | Historial de mantenimiento                     |             | Nominal                 |
|  | Tipo del último tratamiento superficial        | RMED_TYPE   | Nominal                 |
|  | Tiempo desde el último tratamiento superficial | REMED_TIME  | Ordinal                 |

A continuación, se presenta en GRÁFICO 6 con la cantidad de documentos que requieren variables de entrada de condiciones de clima, tránsito, estructural, construcción e historial de mantenimiento, según la variable de predicción del modelo, obtenidos en función del ANEXO B.






Gráfico 6: Conjunto de variables de entrada requeridos según las variables de predicción, para cada tipo de pavimento.



Se muestra que las variables de condición estructural son las que más se requieren para generar los modelos, por lo que es importante tener registro de la edad del pavimento, los espesores de las capas, la materialidad, etc. Además, las solicitaciones de tránsito y clima son variables necesarias para modelar deterioros con alta precisión y generalización. En los pavimentos con mejora resulta lógico que lo segundo más importante sea contar con el registro de las actividades de M&R que se han realizado.

### 4.2.3 Metodología de modelamiento

#### 4.2.3.1 Serie de tiempo v/s multi-variable

Como se mencionó, existen enfoques de modelamiento multi-variable, serie de tiempo y mixto. En los modelos de deterioro el enfoque depende de la disponibilidad de las evaluaciones de las variables de entrada y de la complejidad que se le quiere dar al modelo. Un modelo con serie de tiempo pronostica considerando el deterioro incremental, por lo que requiere datos históricos, lo cual es caro y engorroso si es que no se le ha hecho un seguimiento antes. Esto concuerda con lo visto en la TABLA 19, donde la mayoría de los modelos se determinan con enfoque multi-variable. Además, se nota que hacer un modelamiento mixto es una buena alternativa cuando se quiere mayor precisión en el modelo, sin la necesidad de tener todas las variables históricas.

Tabla 19: Número y porcentaje de estudios realizados con los enfoques de modelamiento, según tipo de pavimento.

|  |           | <b>Pavimento Flexible</b> | <b>Pavimento Rígido</b> | <b>No pavimentado</b> | <b>Pavimento con mejora</b> |
|--|-----------|---------------------------|-------------------------|-----------------------|-----------------------------|
| <b>Multi-variable</b>                    | <b>71</b> | 48                        | 15                      | 3                     | 5                           |
|  |           | 68%                       | 21%                     | 4%                    | 7%                          |
| <b>Serie de tiempo</b>                   | <b>14</b> | 10                        | 4                       | 0                     | 0                           |
|  |           | 71%                       | 29%                     | 0%                    | 0%                          |
| <b>Multi-variable y series de tiempo</b> | <b>27</b> | 14                        | 7                       | 1                     | 5                           |
|  |           | 52%                       | 26%                     | 4%                    | 19%                         |

Okuda et al., (2017), modela el ahuellamiento a partir de datos de series de tiempo tomados cada tres años entre 1998 y 2016; es decir, se tienen seis datos de tiempo para la misma sección. Se excluyen los valores con historiales de reparación, obteniendo un total de 11.883 datos. El modelamiento a tres años es mediante MLR, ANN y RNN. RNN tiene mayor precisión ( $RMSE = 2,27$ ) y MLR la menor precisión ( $RMSE = 2,52$ ); sin embargo, todos los modelos son aceptados y no hay mayor diferencia.

Y. Dong et al., (2019), establece que RNN es una buena herramienta que captura de mejor manera la relación entre las características de la serie transversal y de serie de tiempo, obteniendo mejores resultados en comparación a ANNs. Marcelino et al., (2020), realizan un modelo de predicción de IRI en el tiempo durante toda la vida útil del pavimento. Realizó un análisis en serie de tiempo y mixto, ambos con variables históricas de los cuatro últimos años con datos combinados de LTPP y evaluaciones en la carretera portuguesa.

Ya sabemos las ventajas y desventajas de los distintos enfoques de modelamiento. El GRÁFICO 7 demuestra la relación entre el enfoque de modelamiento y la herramienta de ML.




Gráfico 7: Enfoques de modelamiento según herramienta de ML

Nuevamente se ve que los modelos multi-variables son la mejor opción, ya que permiten tener una base de datos más extensa; sin embargo, el modelamiento mixto es una buena alternativa cuando se quieren tener modelos más precisos. ANN, SVM, RF/DT, modelamiento híbrido, RNN y regresión son buenas alternativas de herramientas de ML para modelar con datos históricos

Kargah-Ostadi et al., (2010), aumenta la precisión en la predicción de IRI usando cómo variable de entrada el IRI anterior, sin necesidad de tener un historial de mediciones, mediante ANN. Los modelos con enfoque multi-variable son los indicados cuando se quieren tener respuestas rápidas, pero no tendrán alta precisión a largo plazo, por lo que el modelo debe ser autocalibrado a medida que pasa el tiempo.

#### 4.2.3.2 Proyección de predicción

La proyección de predicción puede ser a corto, mediano o largo plazo. La FIGURA 14 muestra los documentos más recurrentes para cada proyección de predicción, dejando en el centro la predicción completa. Se puede ver que la mayoría de los estudios predicen durante toda la vida útil del pavimento, ya que uno de los objetivos principales es obtener un estimativo del comportamiento del pavimento en el corto y largo plazo para ser significativo en el SGP.

Algunos documentos predicen a corto plazo y proyectan la predicción a más periodos para abarcar la vida útil, tal como lo hace Marcelino et al., (2020), en la predicción de IRI pronosticado a 1 y 4 años combinado para prolongar la predicción. Para esto utilizó variables históricas durante los últimos cuatro años y una base de datos combinada con datos reales y datos de LTPP, mediante un aprendizaje por transferencia. Los modelos resultantes de aprendizaje por transferencia superan a los modelos de referencia hasta en un 20% cuando se predice a largo plazo. Mientras más datos se tengan y en mayor periodo, más precisa será la predicción a largo plazo. Según S. M. Piryonesi & El-Diraby, (2020), el aumento en el intervalo de predicción reduce la precisión, mientras que la reducción del número de clases de predicción aumenta la precisión.

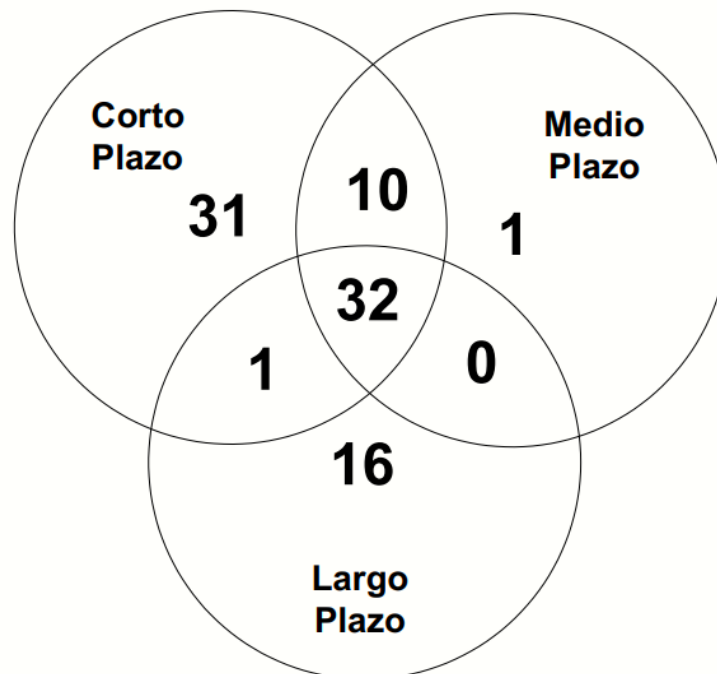


Figura 14: Recurrencia de proyección de predicción en documentos

La siguiente mayoría la obtienen los documentos que predicen a corto plazo, resultando importante mencionar que en tales casos se emplearon en su mayoría herramientas de ML cuya aplicación no considera la dependencia temporal de los datos (ver GRÁFICO 8). Una de las técnicas de pretratamiento de la base de datos es la separación de variables en cadenas temporales, es decir, las variables sólo se consideran desde que se haya realizado alguna mejora en el pavimento o en su defecto desde el inicio si no posee tratamiento. Esto es una buena alternativa para simplificar el modelo, pero lo condiciona a una predicción a corto plazo. Tal como hace S. Inkoom et al., (2019), en el desarrollo de un modelo que predice la clasificación de grietas de una sección de carretera, donde la edad del pavimento se considera desde alguna mejora. Usan modelos de ANN y DT, obteniendo buena capacidad de predicción en ambos casos.




Gráfico 8: Relación entre la herramientas de ML y la proyección de predicción

#### 4.2.3.3 Nivel de red v/s nivel de proyecto

La gestión de pavimentos se desarrolla a nivel de red y proyecto. Un estudio a nivel de red permite tomar decisiones más generales, por lo que requiere datos menos específicos y más fáciles de obtener; en cambio, el estudio a nivel de proyecto requiere más detalles de algún segmento que pertenezca a la red vial. El GRÁFICO 9 muestra que la mayoría de los estudios se hacen a nivel de red, lo cual resulta lógico ya que los estudios pueden usar la base de datos disponible de los SGP que evalúan sus pavimentos de manera regular y sin tanto detalle y rigurosidad. (Kargah-Ostadi et al., 2010)

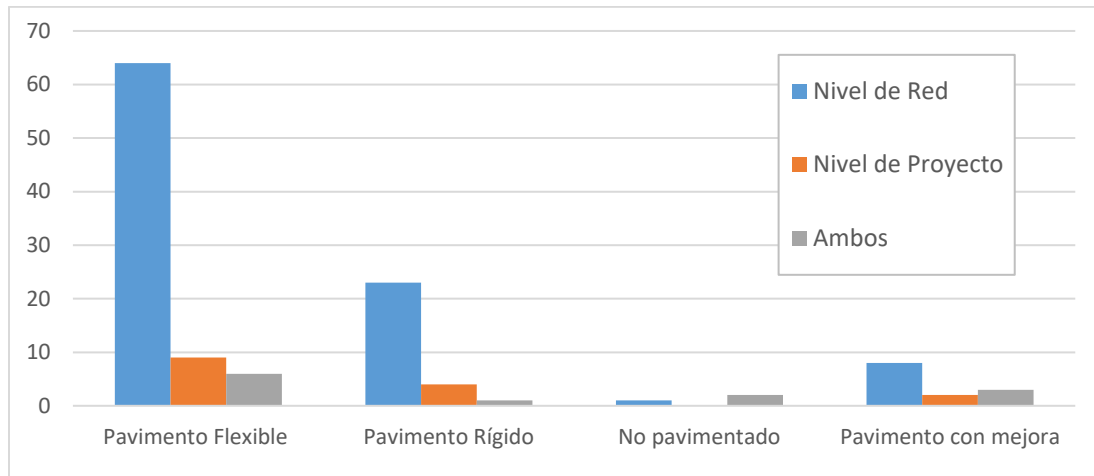



Gráfico 9: Recurrencia de nivel de estudio para los distintos tipos de pavimento.

Últimamente, las agencias se han preocupado de tener una base de datos completa, invirtiendo en maquinarias de evaluación continua que permiten generar modelos de predicción a nivel de proyecto y red, como lo son los dispositivos de deflexión continua (Elbagalati et al., 2017). Esto motiva a los autores a generar modelos de predicción a nivel de proyecto tanto como a nivel de red en la actualidad.

#### 4.2.4 Variables de predicción

Las variables de predicción corresponden a la(s) salida(s) que tendrán los modelos, algunas predicen índices de condiciones de pavimento, otras predicen deterioros y otras simplemente variables que influyen directamente en el desempeño del pavimento.

El GRÁFICO 10 presenta la cantidad de estudios presentes según el tipo de pavimento para cada variable de predicción:






Gráfico 10: Variables de predicción según tipos de pavimentos.

IRI es el indicador más modelado, muchos autores lo establecen como un indicador práctico y universal para cuantificar la rugosidad, reflejando la calidad de conducción y el nivel de comodidad del usuario. Además, MEPDG lo establece como uno de los principales indicadores de desempeño funcional y aporta alrededor del 95% de la información sobre la capacidad de servicio del pavimento. (Abdelaziz et al., 2020; Kargah-Ostadi, 2014; Kargah-Ostadi & Stoffels, 2015; Marcelino et al., 2019, 2020; Nguyen et al., 2019). Le sigue el agrietamiento, deterioro que determina la prioridad de rehabilitación ya que es un indicador de inicio de destrucción prolongada del pavimento, y el PCI, índice universalmente aceptado para describir el desempeño del pavimento.

A continuación, se presentan algunos estudios de las variables de predicción:

## AGRIETAMIENTO

Lou et al., (2001), desarrolla modelos de predicción a corto plazo del Índice de Agrietamiento, mediante ANNs con Back-Propagation en la red de carreteras de Florida. La red tiene buena capacidad para aprender la progresión de las grietas de la base de datos y predecir el índice con alta precisión, superando considerablemente el modelo de regresión lineal. Además, la red es capaz de incluir en un mismo modelo los pavimentos rígidos y flexibles.





Hongren Gong, Sun, & Huang, (2019), propone un modelo DT reforzado por *Gradient Boosted Model*, (GBM – Modelo Impulsado por Gradiente, en español) para predecir el agrietamiento longitudinal y el agrietamiento por fatiga en pavimentos flexibles. El modelo final es comparado con RF aleatorio y con las funciones de transferencia calibradas de MEPDG. Usa un conjunto pequeño de LTPP, separados en subconjunto de entrenamiento (80%) y validación (20%). La función de MEPDG no logra capturar las variables de entrada y, por ende, no genera una predicción confiable, esto puede ser porque el conjunto de datos no es suficiente o por deficiencias en la formulación. DT reforzado y RF obtienen resultados similares y significativamente mejores.

Sylvester Inkoom et al., (2019), genera varios modelos de predicción de agrietamiento mediante distintas herramientas de ML en función de calificaciones de condición de pavimento anteriores y variables independientes. Se usan modelos de partición recursiva, DT, RF, KNN, Naïve Bayes y MLR. Los resultados indican que todos los modelos son capaces de predecir agrietamiento con precisión ( $0,6 < R^2 < 0,9$ ;  $0,4 < RMSE < 0,9$ ) y que las variables más influyentes son la edad, ADT y la clasificación de agrietamiento del año anterior. KNN es el modelo que obtiene mejores resultados.

## AHUELLAMIENTO

Abiola et al., (2012), desarrolla modelos de predicción a tres años de ahuellamiento con ANN para la autopista Lagos-Ibadan, Nigeria. El modelo más óptimo tiene 11 variables de entrada, 24 neuronas en la capa oculta y la neurona de salida que es el ahuellamiento. El coeficiente de determinación aumenta a medida que el modelo predice a más años, aumentando cada vez la precisión y predicción del modelo. Heidari et al., (2018), también desarrollan un modelo de predicción de ahuellamiento en pavimentos de carreteras forestales mediante ANN y regresión logística. Mediante el modelo ANN obtiene las variables más influyentes: espesor del pavimento, deflexión y ESAL. ANN es más preciso que la regresión logística, sin embargo, ambos modelos son precisos y generalizables ( $RMSE < 0,27$ ).

Hongren Gong et al., (2018), desarrolla dos modelos de RNNs para mejorar la precisión de predicción de ahuellamiento de la función de transferencia MEPDG. El primer modelo ( $NN_3$ ) tiene tres variables de entrada que corresponden a datos predichos por MEPDG, y el segundo modelo ( $NN_{20}$ ) agrega 17 variables al modelo anterior, incluyendo variables de tránsito, estructurales, climáticas y de materiales. Los modelos finales se comparan con dos modelos de regresión múltiple MLR que contienen las mismas variables de entrada que los anteriores ( $MLR_3$  y  $MLR_{20}$ ). Los modelos RNNs obtienen comportamiento predictivo significativamente mejor que MLRs; sin embargo, resultan complejos de interpretar. Los modelos MLR, tanto para 3 y 20 variables, no logran el comportamiento esperado en el MEPDG para pavimentos estatales. Las RNNs obtienen mejores resultados, tanto para 3 y 20 variables de entrada, siendo  $NN_{20}$  el modelo con los mejores resultados. Finalmente, se observa que la función de transferencia de MEPDG no considera variables importantes en el modelamiento como lo vacíos de aire y el volumen de tránsito, lo cual da explicación a los malos e insatisfactorios resultados obtenidos por MEPDG.



## BACHES

Heidari et al., (2018), predice baches en pavimentos de carreteras forestales mediante ANN y regresión logística. Generando un modelo de ANN muy bueno capaz de obtener las cinco variables más influyentes: historial de mantenimiento, material del pavimento, ESAL, pendiente y drenaje. ANN es más preciso que la regresión logística, sin embargo, ambos son precisos y generalizables ( $RMSE \leq 0,253$ ).

## CONDICIÓN DEL PAVIMENTO



Shalaby & Reggin, (2007), generan dos modelos de predicción de PCR mediante ANNs en función del IRI y el agrietamiento por fatiga.  $ANN_1$  tiene cuatro variables de salida en las que categorizan el PCR y  $ANN_2$  predice PCR como una variable discreta. En ambos casos no se obtienen buenos resultados, por lo que se concluye que IRI y ahuellamiento no son suficientes para predecir PCR.

Elbagalati et al., (2017), genera un modelo de predicción de SCI usando datos de RWD para evaluar las condiciones estructurales. Desarrollan DTs que consideran condiciones funcionales y estructurales del pavimento en la toma de decisiones, resultando modelos posibles de usar en SGP de Luisiana. Esto mejora la inversión de M&R en pavimentos de alto volumen de tránsito. Elbagalati et al., (2018) extienden la investigación modelando con ANNs, resultando un modelo con rango de precisión general aceptable mayor a 93,2%.

## CONDICIÓN SUPERFICIAL

Whiteley-Lagace et al., (2011), propone un modelo de predicción de condición superficial en pavimentos flexibles, rígidos y caminos sin pavimentar, con datos recopilados entre 2005 y 2009 en una red de carreteras de bajo volumen. El documento genera un DT que logra planes presupuestarios a 5 y 10 años y desarrolla recomendaciones para mejorar la recolección de datos.

Rosada et al., (2019), genera un modelo del SDI en carreteras mediante ANNs basado en los datos de la encuesta RCS en los pavimentos entre las regiones de Betung y Palembang, Indonesia. En comparación con los modelos de regresión lineal, ANN obtiene mejores resultados de predicción. ANN puede ser utilizado para predecir SDI sólo con los datos de la encuesta y la edad del pavimento, logrando buena capacidad y flexibilidad en la predicción.





## ESFUERZO

Esfandiarpour & Shalaby, (2017), genera un modelo de predicción de cumplimiento de fluencia en pavimentos flexibles. Se modela mediante MLR Y ANN, y se comparan con modelo generalizado de MEPDG. La base de datos es obtenida de pruebas de laboratorios de 14 tipos de mezclas de concreto asfáltico, en total resultan 861 mediciones. Los resultados indican que MEPDG sin calibración local predice mal los valores de fluencia, por lo que la calibración es un paso necesario para implementarlo, además, MEPDG es un modelo genérico que no predice con precisión para mezclas en climas fríos ( $R^2 = 0,535$  y  $S_e/S_y = 0,686$ ). MLR ( $R^2 = 0,830$  y  $S_e/S_y = 0,421$ ) y ANN ( $R^2 = 0,874$  y  $S_e/S_y = 0,357$ ) mejoran la confiabilidad de las predicciones, siendo ANN el que predice el cumplimiento de fluencia con el error más bajo.

Kaya et al., (2018), desarrolla modelos de predicción mediante ANN que estiman la tensión de flexión de arriba hacia abajo calculada en pavimentos rígidos de aeropuerto. Usa una base de datos sintética generada con el diseño del *Federal Aviation Administration Rigid and Flexible Iterative Elastic Layer Design* (FAARFIELD - Diseño de capa Rígida y Flexible de interacción Elástica de la Administración Federal de Aviación, en español), para compararlo con el modelo del *Finite Element Analysis Federal Aviation Administration* (FEAFAA - Análisis de Elemento Finito de la Administración Federal de Aviación, en español), usando las mismas variables de entrada y sus respuestas críticas asociadas. Se consideran dos casos de cargas diferentes (carga mecánica y carga mecánica de T° simultánea) y se desarrolla un modelo ANN para cada caso. Con ANN se obtienen buenas predicciones y en un tiempo considerablemente menor, el análisis dimensional es práctico para disminuir las variables de entrada de 6 a 4.

## IRI

Huang & Moore, (1997), generan modelos de predicción binarios mediante MLR y ANNs. Predice la probabilidad de que un pavimento flexible esté en un nivel de rugosidad, convirtiéndose en uno de los primeros acercamientos a la predicción de IRI. La respuesta es la probabilidad binaria de estar en un nivel de deterioro de rugosidad dado, siendo 1 si el pavimento está en un nivel de deterioro de rugosidad dado y 0 si el pavimento se encuentra en cualquier otro. ANN tiene capacidad de predicción superior a MLR, ya que los datos están mal condicionados para ser aplicados en regresión.





J. Choi et al., (2004), usa datos de LTPP para ver la contribución de las variables de materiales y construcción de pavimentos de concreto asfáltico en modelos de predicción de IRI. El modelo se determina con ANN entrenada con Back-propagation (6-10-1) y se compara con un modelo MLR. ANN resulta una buena herramienta de ML para predecir IRI y obtener las variables más influyentes. Attoh-Okine, (2005), también generan modelos de predicción de IRI mediante ANNs y redes funcionales en pavimentos flexibles. Se obtienen resultados precisos y generalizables, por lo que las redes funcionales son una buena alternativa ya que no requiere muchos datos, necesita poco conocimiento del dominio y modela con funciones simples para desarrollar la progresión.

Najjar & Felker, (2006), da énfasis en la importancia de predecir la progresión de la rugosidad en los pavimentos de *Portland Cement Concrete* (PCC - Concreto de Cemento Portland, en español), puesto que el modelo actual de KDOT se basa en este indicador. Desarrollan una ANN de tres capas (19-10-1) con variables de entrada relacionadas con factores de diseños de pavimento, los parámetros del material de concreto, tratamiento de la subrasante, propiedades del suelo de los cimientos, cargas de tránsito, condiciones de clima y la calidad de construcción. El modelo resultante es preciso en la predicción de IRI en función del tiempo con  $R^2 = 0,9$ .

Thube, (2012), predice IRI y tres deterioros superficiales mediante ANN aplicado en pavimentos flexibles de volumen de tránsito bajo en India, comparado posteriormente con HDM-4. ANN obtiene mejores resultados, ya que son aplicables a todo tipo de terreno: llano, ondulado y montañoso, obteniendo un  $R^2$  mayor a 0,97 para todos los modelos de deterioros.

Abd El-Hakim & El-Badawy, (2013), también desarrollan un modelo de predicción de IRI mediante ANN en pavimentos rígidos. Las entradas del modelo son variables estructurales, de condición del pavimento y condiciones climáticas, todos obtenidos de LTPP para secciones de *Jointed Plain Concrete Pavement* (JPCP - Pavimento de Hormigón Liso Articulado, en español). El modelo ANN se compara con MEPDG, ANN obtiene mayor precisión de predicción ( $R^2 = 0,828$  y  $S_e/S_y = 0,414$ ) que el modelo MEPDG ( $R^2 = 0,584$  y  $S_e/S_y = 0,643$ ), además, el sesgo de la predicción de IRI es significativamente menor con ANN.

Mehran Mazari & Rodriguez, (2016), usan dos conjuntos de datos de LTPP para predecir IRI, utilizando tres variables: número estructural, edad del pavimento y ESAL. Primero hace a modelación multi-variable con GEP y luego mejora el modelo con enfoque híbrido, optimizándolo con ANN. El modelo híbrido predice eficazmente el IRI, el  $R^2$  aumenta de 0,9053 (GEP) y 0,9251 (ANN) a 0,9941 (GEP-ANN). Finalmente, utiliza variables históricas para predecir mediante GEP,  $R^2 = 0,989$  para conjunto de entrenamiento y validación, obteniendo buenos resultados en general.





Georgiou et al., (2018), genera modelos de predicción de IRI a corto plazo mediante ANN y SVM usando datos de rugosidad recopilados periódicamente durante 7 años en carreteras de gran volumen. Los datos de los primeros seis años son usados como variables de entrada en los modelos. ANN tiene una buena convergencia y resulta ligeramente más preciso en la predicción (nivel de confianza de 95%). Ambos modelos son capaces de predecir IRI y resultan una herramienta útil para apoyar la toma de decisiones con muy buena capacidad predictiva y generalización.

## PCI

Yan & Zhang, (2011), establecen que hay cuatro parámetros que describen el estado de un pavimento asfáltico: PCI, *Structure Strength Index* (SSI – Índice de Resistencia de la Estructura, en español), IRI y *Skid-Resistance Index* (SRI - Índice de Resistencia al Deslizamiento, en español). Es por esto que selecciona SSI, IRI y SRI como variables independientes para predecir PCI mediante SVM optimizado con PSO. Los datos recopilados se dividen en tres: entrenamiento, validación y prueba y se hace una comparación de tres modelos. El primer modelo sólo considera IRI como variable independiente, el siguiente considera IRI y SSI y el último considera las tres variables independientes ya mencionadas. En los resultados se muestra que mientras más variables de entrada se tenga, la predicción estará más cercana a los valores reales.

Shahnazari et al., (2012), genera modelos de predicción de PCI usando ANN y GP. Se usan datos evaluados de deterioros superficiales de más de 1.250 [km] de carreteras en Irán, correspondientes a las variables de entrada del modelo. Ambos modelos son aceptables en la predicción de PCI, además, son simples, accesibles y aplicables en SGP; sin embargo, ANN fue más preciso que GP.

Kırbaş & Karaşahin, (2016), desarrollaron tres modelos diferentes para predecir PCI en función de la edad del pavimento, y se aplicaron a las redes viales urbanas en Samsun, Turquía. Los modelos utilizados fueron regresión, MARS y ANN. MARS es capaz de predecir PCI ( $R^2 = 0,7238$ ) ligeramente mejor al modelo de regresión ( $R^2 = 0,70$ ); ambos modelos se consideran aceptables. La arquitectura óptima de ANN se determinó iterando múltiples capas y neuronas, resultando 1-3-1 la más óptima para la predicción con la edad del pavimento de entrada, el modelo fue entrenado con LM, con todas las variables normalizadas. ANN es el más apropiado para predecir PCI ( $R^2 = 0,7456$ ); sin embargo, no hay mayor diferencia entre los tres modelos, todos son aceptados para ser usados en el SGP, con condiciones climáticas y de tránsito similares.





El-Diraby & Piryonesi, (2019), generan un modelo de predicción de PCI para carreteras asfaltadas en el corto y mediano plazo, tomando en cuenta la variación del clima. Se usan datos de más de mil secciones presentes en LTPP. Se modeló mediante DT reforzado, RF, Naïve Bayes, regresión logística y KNN, entrenados y validados con validación cruzada de diez veces y, luego, probados con datos reales de Ontario. DT reforzado obtuvo los mejores resultados, siendo los clasificadores lineales (Bayes y regresión logística) los modelos con menor precisión.

Jalal et al. (2017) y Younos et al.(2020), desarrollan un modelo de predicción de PCI con enfoque multi-variable y ANN, teniendo en cuenta las cargas de tránsito y los factores ambientales. Younos et al., (2020), usa 89 secciones de LTPP, las cuales cubren las cuatro regiones climáticas de EE.UU.: húmedo, congelado húmedo, seco y congelado seco. Jalal et al., (2017), generan su propia base de datos a partir de mediciones durante tres años consecutivos en pavimentos flexibles, rígidos y de concreto asfáltico presentes dentro de la Universidad de Texas. Se hace una iteración de distintas arquitecturas para ANN, comparándolas según MAPE, RMSE y  $R^2$ . 5-13-9-1 resulta la mejor arquitectura, significando aumento en el desempeño y precisión del modelo ( $MAPE = 13,39$ ,  $RMSE = 17,72$  y  $R^2 = 0,974$ ).

Karballaezadeh et al., (2020), genera un modelo de predicción de PCI basándose en los datos de deflexión de la superficie de la prueba FWD y evaluaciones pasadas de PCI tomadas en 236 segmentos de pavimento de Teherán-Qom, Irán. Usa ANNs y sus modelos híbridos optimizados con LM, SCG, ICA y GA, y, finalmente, se combinan los resultados con el método *Committee Machine Intelligent Systems* (CMIS - Sistemas Inteligentes de Máquinas del Comité, en español). CMIS obtiene los mejores resultados, convirtiendo el modelo en una opción de predicción de PCI sin la necesidad de hacer inspección manual y visual de los pavimentos.

## **PÉRDIDA DE ÁRIDOS**

A. S. Oladele, (2013), genera un modelo prediciendo la pérdida de áridos en caminos no pavimentados, usando datos para Botsuana, evaluados en tres años: 2002, 2005 y 2008. Modela mediante ANNs entrenada con Feed-Forward (FFNN) y MLR, obteniendo predicciones más precisas con FFNN ( $R^2 = 0,94$ ); sin embargo, MLR también resulta una alternativa eficaz ( $R^2 = 0,74$ ). Posteriormente, Oladele, (2017), expande su estudio a modelando la pérdida de árido en caminos no pavimentados utilizando un modelamiento híbrido de ANN optimizada con un mapa basado en GIS que muestre las condiciones del camino; es decir, GIS muestra la pérdida de árido instantáneamente definiendo un umbral de condición máximo ( $GVL < 0,3$  aceptable) para aplicar intervenciones de mantenimiento óptimas. FFNN optimizado con herramientas innovadoras de monitoreo obtiene resultados precisos y aplicables ( $R^2 = 0,95$ ;  $MSE = 0,055$ ).



## PSI

Tabatabaee et al., (2013), utilizan un modelo híbrido de dos etapas para predecir PSI con alta precisión. Considera variables estructurales, de solicitaciones climáticas y de tránsito, métodos de construcción e historial de M&R para la predicción. Realiza un análisis de sensibilidad para hacer más rápido y sencillo el modelamiento, resultando las variables de estacionalidad y clima más influyentes que las cargas de tránsito. El espesor de la sub-base y los materiales usados en la construcción no tienen influencia en la predicción.



## VIDA ÚTIL RESTANTE

Karballaezadeh et al., (2019), genera un modelo de predicción de RSL mediante SVM, ANN y SVR optimizado con un filtro de partículas (SVR-PF). SVR optimizado obtiene un 95% de precisión en la predicción de RSL, significando un método que puede reducir considerablemente los costos (ahorro por ser un método no destructivo como HDW) y elimina la influencia del tránsito. Nabipour et al., (2019), generan modelos de predicción de RSL en 105 segmentos de pavimentos flexibles, utilizando como entrada daños superficiales del pavimento. Se utilizan tres herramientas: SVR, SVR optimizado con FOA y GEP, obteniendo mayor precisión con este último. Por lo tanto, GEP es útil para predecir RSL generando un modelo que optimiza la precisión, robustez y confiabilidad para calibrar modelos anteriores.

## OTROS

BCCI: S. Dong et al., (2019), predice BCCI mediante un modelo híbrido que mezcla una red neuronal con un sistema difuso denominada *Fuzzy Neural Network* (FNN - Red Neuronal Difusa, en español). FNN usa 10 variables de entrada, determinadas luego del análisis de sensibilidad del modelo y se prueban muestras de núcleo y secciones de pavimento deterioradas. El modelo resultante obtiene una precisión del 88,4% entre los datos de entrada y salida. Luego se compara con los resultados de la prueba *Ground Penetrating Radar* (GPR – Georradar, en español) realizada en la misma sección, obteniendo resultados similares. FNN resulta efectivo para predecir BCCI aplicable en ingeniería. Se puede evaluar la condición de la capa base efectivamente con unas pocas muestras e inspecciones superficiales de pavimentos asfálticos estabilizados con cemento.

Coefficiente de fuerza lateral: Bosurgi & Trifirò, (2005b), proponen un modelo de predicción de SFC mediante ANN aplicado a una autopista de Italia. La base de datos evalúa SFC en pavimentos con mejora (2001, 2002 y 2003), SFC en los mismos pavimentos antes de la mejora en el año 1997 y datos de tránsito. La red neuronal es compuesta por tres capas, la primera capa tiene dos neuronas (SFC en 1997 y tránsito) y la última predice SFC promedio. El fenómeno queda bien interpretado y logra descifrar las correlaciones internas entre las variables. Posteriormente, expanden el estudio añadiendo el modelo de predicción de accidentes, mediante ANNs. (Bosurgi & Trifirò, 2005a)



ESAL: Tiğdemir, (2014), propone dos modelos de predicción de KESAL, usando ANN y regresión estadística multivariada, con datos evaluados de condiciones climáticas y estructurales. ANN obtiene  $R^2 > 0,976$  en la etapa de entrenamiento, significando una herramienta extremadamente poderosa para predecir KESAL. Mientras que la regresión no fue capaz de generar el modelo, con  $R^2 = 0,68$ . Los modelos de ANNs resultan mucho mejor y menos complejos que el diseño de la AASHTO, incluso determinados con las mismas variables de entrada. Por lo tanto, el modelo es una buena alternativa para reemplazar la ecuación de diseño de pavimento flexible de la AASHTO a largo plazo, mejorando precisión y evitando sobre-estimación.

Falla de juntas JPCP: W. Wang et al., (2017), modelan con dos herramientas de ML la predicción de fallas de JPCP con una base de datos que cuenta con datos históricos y medidos. Ambos modelos, regresión no lineal y ANN, tienen mala capacidad de predicción, sin embargo, el de regresión tiene peores resultados, esto se debe a que la base de datos no es suficiente. Finalmente, compara la predicción con el modelo de Markov que tiene mejores resultados, pero sólo considera el estado actual y pasado y no las variables de diseño y solicitaciones, además, no tiene la capacidad de actualizarse. Por lo tanto, el modelo de Markov será el más óptimo cuando se tenga una base de datos limitada, pero sólo será útil en predicciones a corto plazo y sin singularidades de condiciones externas.

Número de Fricción (FN): Marcelino et al., (2017), aplicaron regresión lineal con aprendizaje supervisado para predecir FN en pavimentos asfálticos, utilizando la herramienta "scikit-learn" de Python. Resulta sencillo obtener el algoritmo con scikit-learn; sin embargo, la herramienta de ML no es la más óptima para la predicción. Se debe aprovechar la base de datos LTPP y alguna herramienta de modelamiento no-lineal para obtener mejores resultados, la regresión lineal genera el modelo con un índice de dispersión  $R^2 = 0,574$ .

Permeabilidad: Nivedya & Mallick, (2018), presentan un modelo de permeabilidad de mezclas de hormigón asfáltico en caliente mediante ANNs, usando datos de permeabilidad de pruebas en cinco sitios, materiales y datos de la mezcla inicial. Usa la matriz de confusión para validar el modelo. ANN logra una clasificación con buen ajuste y precisa, incluso cuando las variables de entrada no son las suficientes (es necesario incluir variables estructurales y de construcción) y cuando la base de datos no era muy grande.

Temperatura superficial: Qiu et al., (2020), desarrolla un modelo de predicción de temperatura superficial de pavimentos asfálticos en invierno, explorando la correlación entre la temperatura y factores meteorológicos. Usa tres herramientas de ML para hacer la predicción: DT, RF y regresión lineal; obteniendo mejores resultados con DT ( $MSE < 1,5$ ), teniendo la capacidad de predecir con alta precisión y generalización.

#### 4.2.5 Herramientas de Machine Learning

Las herramientas de ML cada vez son más desarrolladas, debido a que han demostrado ser eficientes para dar solución a problemas complejos. Una de las más famosas es la ANN, lo cual queda demostrado en el GRÁFICO 11, ya que se dice es la herramientas de ML más eficiente creada con el fin de imitar el cerebro humano, por lo que el modelo se va actualizando automáticamente a medida que va teniendo nuevos conocimientos.

ANN resulta la herramienta de ML más usada tanto para los modelos de deterioro como para los tratamientos de M&R. En modelos de deterioro, las herramientas que más se repiten son la regresión y los modelos híbridos. Los modelos de regresión son una herramienta de ML fácil de implementar y un buen punto de comparación para validar un modelo. Los modelos híbridos son métodos de optimización de modelos de ML que permiten obtener mejores resultados aún, por lo que también son de gran interés.






Gráfico 11: Herramientas de ML según modelos de deterioro y M&R.

##### 4.2.5.1 Modelos de deterioro

A continuación, se presentan estudios desarrollados con las distintas herramientas de ML para generar modelos de deterioro.



## Artificial Neural Networks



Jidong Yang et al., (2003), propone un modelo alternativo al de FDOT para predecir PCR. La investigación desarrolla modelos de predicción con ANNs y modelos AR para pavimentos flexibles y rígidos, utilizando datos históricos de los últimos 5 años. Se hace una predicción a corto y mediano plazo y se comparan los modelos mediante el gráfico de dispersión. La predicción mediante ANN a un año es la que tiene mejores resultados. Los modelos AR obtienen malos resultados a corto y mediano plazo, sin precisión ni capacidad de generalización. Por lo tanto, sólo el modelo ANN a corto plazo significa una alternativa eficaz y razonable al modelo de predicción de FDOT.

J. Yang et al., (2006) genera un modelo de predicción de agrietamiento en pavimentos flexibles modelado con ANN y cadenas de Markov recurrentes, utilizando datos de FDOT. Para predicciones a un año, ambos modelos tienen una precisión parecida; sin embargo, para las predicciones a 3 años, la cadena de Markov recurrente obtiene resultados más consistentes que ANN, ya que tiende a sobreestimar el agrietamiento. Esto puede ser debido a que la arquitectura y los hiper-parámetros de ANN para la predicción a un año no son proyectables a más años y, por lo tanto, una ANN con back-propagation típica no es aplicable para pronósticos de múltiples pasos.

Zhang et al., (2009), genera un modelo de predicción del uso de la carretera China mediante una ANN con Back-propagation. Se establecen cinco niveles del uso de carretera correspondientes a las neuronas de salida. Se usan datos reales de carreteras en Tianjin para entrenar el modelo, obteniendo como resultado una red con predicción progresiva de alta precisión y aplicable al SGP.

Halil Ceylan et al., (2011), proponen un modelo de predicción de SIF a medida que las grietas crecen hacia arriba, en pavimentos rígidos o flexibles con superposición de HMA, como efecto de cargas y diferencias térmicas con y sin cargas de refuerzo. Se utiliza una base de datos sintética obtenida de 100.000 corridas de un programa de elementos finitos, con datos de longitudes de grietas y estructuras de pavimentos. Se desarrollan seis modelos con ANN para diferencias térmicas y doce modelos para cargas de tránsito. Todos los modelos ANN, excepto uno, obtienen  $R^2 > 0,99$ .

Thube, (2012), usa ANNs para predecir agrietamiento, pérdida de áridos, ahuellamiento y rugosidad para carreteras de bajo volumen en India. La base de datos cuenta con seis ciclos de evaluaciones en 61 secciones, tomadas durante 3 años. Se iteran distintas arquitecturas de ANN para obtener la más óptima, obteniendo un modelo de predicción de deterioro superficial satisfactorio, incluso mejor en comparación con HDM-4. Yao et al., (2019), extiende la investigación anterior para predecir cinco condiciones del pavimento flexible: ahuellamiento, agrietamiento, IRI, SFC y condición del pavimento, mediante ANNs. El modelo cuenta con 30 variables de entrada y se evalúa sus influencias en cada uno de los indicadores; ANN demuestra gran potencial para la predicción precisa con  $R_{prom}^2 = 0,8692$ . El análisis de sensibilidad del modelo permite mejorar la precisión del modelo y evitar el sobre-ajuste.





Ziari, Sobhani, et al., (2016), generaron modelos de predicción de IRI con ANN en el corto y largo plazo. Los modelos ANNs se compararon con modelos Group Method of Data Handling (GMDH, Método Grupal de Manejo de Datos en español) en relación a capacidad y confiabilidad. GMDH es un agrupamiento polinomial, el cual es desarrollado en 1, 2, 3 y 4 grados. Tanto ANN como GMDH tienen 9 variables de entrada. GMDH no es capaz de predecir el desempeño del pavimento a corto y largo plazo; por el contrario, ANN con una capa oculta es capaz de predecir a corto y largo plazo con precisión satisfactoria, en todos los casos  $R^2 > 0,9$ . Lucey et al., (2019), usan dos tipos de ANNs para predecir IRI a partir de tránsito, edad y número estructural (SN, Structural Number). El primer modelo usa una estructura de retro-propagación (Feed-Forward) y retroalimentación (Backpropagation) con datos de LTPP separados en sub-conjuntos de entrenamiento, validación y prueba.

Amín & Amador-Jiménez, (2017), generan un modelo de predicción de PCI mediante una ANN entrenada con Back-propagation y función de activación sigmoidea. El modelo se aplica a pavimentos flexibles y rígidos de Montreal. Se hace un análisis de sensibilidad, donde se obtiene que PCI tiene relación inversa con ESAL, ADT y AGE, y relación directa con SN y PT. La diferencia de PCI entre el año actual y el anterior es la variable que más tiene influencia en la predicción.

Yamany et al., (2020), genera modelos de predicción de IRI usando datos generales y validados para casos en particular, con el fin de demostrar que puede no ser la estimación más óptima debido a la variación en las prácticas de las distintas agencias, procesos comerciales, fondos disponibles, inversiones en mantenimiento y rehabilitación, etc. Los departamentos de transporte pueden basarse en modelos de otras agencias siempre y cuando las consideraciones sean similares. Para probar esto, utilizó una base de datos de ocho estados de LTPP para estimar modelos de regresión y ANNs comparativos y aleatorios. ANN obtiene mejores predicciones que regresión en general, pero para la evaluación individual ocurre lo contrario. El modelo de regresión es más fácil de interpretar y demostrar las variables que más influyen en el deterioro, por lo que podría ser una buena alternativa para calibrar a un estado en particular.

### **Support Vector Machine**

Ziari, Maghrebi, et al., (2016), generan un modelo de predicción de IRI utilizando SVR con tres Kernels diferentes: Polinomio, Pearson VII Universal y función de base radial; los núcleos polinomiales se prueban con grados del 1 al 3, lo que genera cinco modelos diferentes. Se utiliza una base de datos de LTPP con nueve variables independientes, con la que se hace cross-validation de 10 sub-conjuntos para entrenar el modelo. El polinomio de grado dos obtuvo mejores resultados que los otros polinomios; sin embargo, SRV con Pearson VII Universal fue el más preciso y generalizable de todos ( $MAE = 0,1489$ ;  $RMSE = 0,2259$ ;  $R = 0,9169$ ). La función de base radial es la que obtiene los peores resultados ( $MAE = 0,3858$ ;  $RMSE = 0,5787$ ;  $R = 0,5592$ ). Sólo los errores de SVR con Pearson VII Universal son aceptados y puede ser usado para predecir IRI con una precisión aceptable.



Gungor & Al-Qadi, (2018), desarrollaron modelos de predicción para calcular la temperatura y el desempeño del pavimento, mediante SVM. Los resultados indican que SVM puede predecir con alta precisión, bajo tiempo de cálculo y con la capacidad de ser actualizable automáticamente. Además, produce recomendaciones para futuros proyectos de recopilación de datos para tener bases de datos más robusta.



### **Decision Tree**

S. Inkoom et al., (2019), predice el agrietamiento del pavimento mediante dos árboles de decisión. El modelo 1 consta de variables de entrada que incluyen solicitudes de tránsito, condiciones estructurales y condiciones históricas de agrietamiento de los cinco últimos años. El modelo 2 considera las mismas variables anteriores, menos las históricas. En ambos modelos se obtienen buenos resultados  $R^2$  de 0,89 a 0,91, RMSE 0,51 a 0,53 y error absoluto promedio de 0,33 a 0,35. Además, hace una comparación con dos modelos de ANNs con arquitecturas distintas: 2 y 1 capa oculta, respectivamente; muestran un aumento del 2% en  $R^2$ , 1,3 – 2,2% menos en RMSE y 0,7 a 1,7% menos de error. Por lo tanto, se obtienen levemente mejores resultados con las ANNs; sin embargo, ambas herramientas resultan eficientes en la clasificación de datos.

M. Pirayonesi & El-Diraby, (2017), generan modelos de predicción de PCI de carreteras flexibles sin mantenimiento, mediante DT. Se hizo una encuesta con expertos y revisión de planes de gestión de pequeños municipios de Ontario para escoger las variables de entrada del modelo: variables de condición actual del pavimento, de condiciones climáticas y condiciones estructurales, tomando en cuenta también el costo de la recopilación de los datos. El modelo se entrenó con 705 datos de LTPP, obteniendo predicción de PCI a tres años con un nivel de precisión del  $58,22\% \pm 4\%$ . Luego, extiende la investigación a una predicción de PCI a corto y mediano plazo, con más datos de 1.000 datos de LTPP y aplicando distintas herramientas de ML que también incluyen DT (El-Diraby & Pirayonesi, 2019). Finalmente, S. M. Pirayonesi & El-Diraby, (2020), modelan PCI con dos tipos de DT y sus modelos potenciados por gradiente, y usando sólo datos gratis disponibles. DT potenciado por gradiente alcanza más del 80% de precisión.

### **Random Forest**

H. Gong et al., (2018), usan un gran conjunto de datos de LTPP para predecir IRI mediante RF y regresión lineal regularizada. Además, se determinan las variables que más influyen en la progresión del IRI. RF logra buen desempeño predictivo en datos de entrenamiento y prueba, con  $R^2$  igual a 0,998 y 0,974 respectivamente; superando la regresión significativamente corrigiendo el sobre-ajuste del modelo final.



Marcelino et al., (2019, 2020), usa RF para predecir IRI con precisión a corto, mediano y largo plazo y con variables de entrada independientes y fáciles de obtener. Sin embargo, Fathi et al., (2019), predice agrietamiento por fatiga mediante RF teniendo un rendimiento razonable pero no preciso; teniendo  $R^2$  de 0,64 y 0,79 y RMSE de 15,66 y 14,49 para los conjuntos de datos de entrenamiento y validación.

### **Programación Genética**

Chang et al., (2008), desarrollan un modelo de predicción de ahuellamiento mediante GP utilizando 8 pavimentos de prueba (272 registros para entrenamiento y 94 para validación). El modelo resulta una buena base para la evaluación de ahuellamiento, teniendo un  $R^2$  de testeo de 0,814.

### **Herramientas de Deep Learning**



RNN tiene la capacidad de predecir la rugosidad mejor que modelamiento con ANNs, siempre y cuando se tenga una base de datos más grande y robusta. Dong et al., (2019) utilizan LSTM para poder capturar de mejor manera la relación entre las características de la serie transversal y de serie de tiempo en la predicción de IRI, en el cual se logra alta efectividad en comparación a distintas herramientas de ML como regresión y ANN.

S. Choi & Do, (2019), construyen un algoritmo RNN para predecir agrietamiento e IRI a largo plazo, utilizando datos históricos de series de tiempo de 10 años (2007 a 2016) incluida en la base de datos coreana. El modelo se desarrolló con el Software público TensorFlow, con variables de entrada de solicitudes de tránsito y clima; logrando mejores resultados en la predicción a largo plazo (8 años). Sin embargo, al necesitar datos históricos de tantos años, por falta de datos no considera como variables independientes los historiales de mantenimiento, vida útil y estructura de los pavimentos, variables importantes en modelos de deterioro de agrietamiento y rugosidad. Se logran buenos resultados en la predicción con alta precisión y buen punto base para indagar en modelos de deterioro de pavimentos de carretera mediante RNN.

Nader Tabatabaee et al., (2013) predicen PSI con alta precisión usando RNN; LSTM es una herramienta del DL que contribuye a la detección de intervalos de tiempos nocivos en secuencia, con esto puede capturar fluctuaciones lo cual no es posible con métodos tradicionales ya que sólo usan características estadísticas para representar impactos.

### **Modelo híbrido**



Son metodologías que se usan para optimizar modelos, en el cual se mezclan distintas herramientas de ML y/o DL. Estas técnicas se pueden mezclar entre ellas y, también, entre técnicas de optimización. A continuación, se presentan algunas de las técnicas encontradas en los papers leídos:



### ANN-GP:

- Qian, (2010), utiliza un modelo híbrido basado en GA y ANN con backpropagation para predecir el desempeño del pavimento rígido. De esta manera mezcla las cualidades que tiene ANN para encontrar un óptimo local con las de GA para detectar el óptimo global. Primero utiliza GA para optimizar los pesos y luego obtiene umbrales iniciales con ANN; finalmente, entrena la red en dirección del gradiente negativo. El modelo híbrido obtiene resultados más precisos que el modelo sólo con ANNs (error promedio de 6,20% y 12,1% respectivamente); es decir, el modelo híbrido predice el desempeño con mejores resultados. GA es adecuado para manejar problemas paralelos a gran escala, obtiene respuestas que convergen más rápido y mejora significativamente la red.
- Karlaftis & Badr, (2015), generan un modelo de predicción de iniciación de agrietamiento utilizando redes neuronales optimizadas genéticamente, en pavimentos asfálticos rehabilitados. GA es utilizado principalmente para optimizar los parámetros de aprendizaje y el total de neuronas ocultas. Se utiliza una base de datos de LTPP y SPS-5, con datos de tránsito, clima, estructurales y de rehabilitación. El análisis de sensibilidad determina que el inicio del agrietamiento depende principalmente del tipo de material usado en el tratamiento, preparación rigurosa de la superficie y mayor espesor del recubrimiento. El modelo final predice con precisión el riesgo de iniciación de grieta luego de la rehabilitación.
- M. Li & Wang, (2018), generan un modelo de predicción de la respuesta de un pavimento asfáltico, usando programación híbrida que optimiza una ANN mediante GP. Se usa una base de datos sintética que simula pruebas FWD considerando propiedades visco-elásticas de la capa asfáltica y la no-linealidad de las capas libres. Para seleccionar las variables de entrada más influyentes se realizaron análisis de regresión y de sensibilidad. El modelo híbrido tuvo mejores resultados que el enfoque tradicional de regresión multi-variable, es un modelo eficaz.

ANFIS: Nguyen et al., (2019), propone tres modelos híbridos para predecir IRI en carreteras basado en GA, PSO y FA, mezclados con un sistema de interferencia ANFIS: GANFIS, PSOANFIS y FAANFIS; los cuales también comparó con una ANN. Utilizó 2811 muestras de carreteras del norte de Vietnam para entrenar y validar los modelos. PSOANFIS es el modelo con los mejores resultados ( $RMSE = 0,145$  y  $R = 0,888$ ). Sin embargo, los otros modelos híbridos tienen resultados aceptables, siendo la ANN el modelo más pobre para predecir IRI. Esto se debe a que los modelos híbridos van reduciendo el error de la predicción.



FUZZY-ANN: Bianchini & Bandini, (2010), predicen el deterioro del pavimento flexible mediante un razonamiento difuso (FUZZY) impulsado por ANNs. Es un modelamiento híbrido que combina la arquitectura de una ANN con la interpretación SI-ENTONCES del sistema difuso. El modelo predice el cambio de la capacidad de servicio del pavimento en función de datos históricos del aumento del tránsito, condiciones estructurales y factores ambientales. Se generaron cinco modelos, uno por cada estación climática; todos con buena capacidad de aproximación y generalización. Hicieron una comparación con los modelos de regresión lineal, teniendo mejores resultados con el modelo FUZZY-ANN.

GRA-SVR: X. Wang et al., (2020), desarrollan un modelo de predicción de desempeño del pavimento usando un modelo híbrido que optimiza SVR con GRA, logrando resolver problemas de factor de consideración único, predicción a corto plazo y susceptibilidad al sobreajuste del modelo SVR tradicional. GRA-SVR resulta con mayor precisión y operatividad que un modelo de MLR, volviéndolo aplicable a predicción de desempeño a corto y largo plazo.

LSTM-ANN: Y. Dong et al., (2019), proponen un modelo de predicción de IRI híbrido que fusiona una NN con Back-propagation (BPNN) y LSTM. LSTM es usado para aprender las características de series de tiempo del clima y BPNN se encarga de las características estructurales y de tránsito, ambos modelados simultáneamente. Inicialmente, se prueba la dependencia El modelo final alcanza un  $R^2 = 0,867$  para la predicción de IRI. LSTM-BPNN es comparado con BPNN, LR y DT, de los cuales el que tiene peor comportamiento es LR ( $R^2 = 0,738$ ) y el mejor es LSTM-BPNN ( $R^2 = 0,867$ ). Por lo tanto, el modelamiento híbrido es el óptimo y preciso para predecir IRI.

#### RF-NN:

- Fathi et al., (2019), desarrolló un modelo híbrido en el cual mejora un modelamiento en RF ajustándolo con la estructura típica de una ANN, el que denominó RF-ANN.
- Hongren Gong et al., (2018), genera un modelo de predicción de ahuellamiento mediante RNNs, el cual ya obtiene una predicción eficiente pero compleja de entender. Es por esto que RF proporciona un enfoque conveniente y preciso para dar interpretación a la RNN.

SVM-ANN: Tabatabaee et al., (2013), utilizan un modelo híbrido de dos etapas; primero aplican SVM para la clasificación estructural de los pavimentos y luego, agregando variables históricas de clima, tránsito, mantenimiento, estructurales y condiciones de construcción, utilizó ANN con backpropagation para predecir PSI. Usó una base de datos mixta, en la que recopilan datos de MnRoad y pavimentos existentes. SVM resulta útil para la clasificación y reducción de variables de entrada, haciéndolo menos complejo y mejorando la capacidad de generalización del modelo. Se obtiene predicción de PSI con precisión, por lo que genera una herramienta eficaz para predecir el comportamiento del pavimento correspondiente al mantenimiento y rehabilitación y la asignación presupuestaria.

#### 4.2.5.2 Herramientas de ML, según índice de modelos de deterioro




Gráfico 12: Herramientas de ML para cada variable de predicción, según tipo de pavimento.

Las herramientas de ML han sido un aporte importante en la predicción precisa de modelos de deterioro. A lo largo del estudio se ha visto que la herramienta más recurrente son las ANNs y que la variable de predicción más usada es el IRI, lo que queda reafirmado con el GRÁFICO 12 para todos los tipos de pavimento.

#### 4.2.5.2.1 Modelos de predicción de IRI mediante ANN

Se hace un estudio especializado de los documentos que predicen IRI mediante ANNs, viendo en detalle la arquitectura de la red (ver GRÁFICO 13).

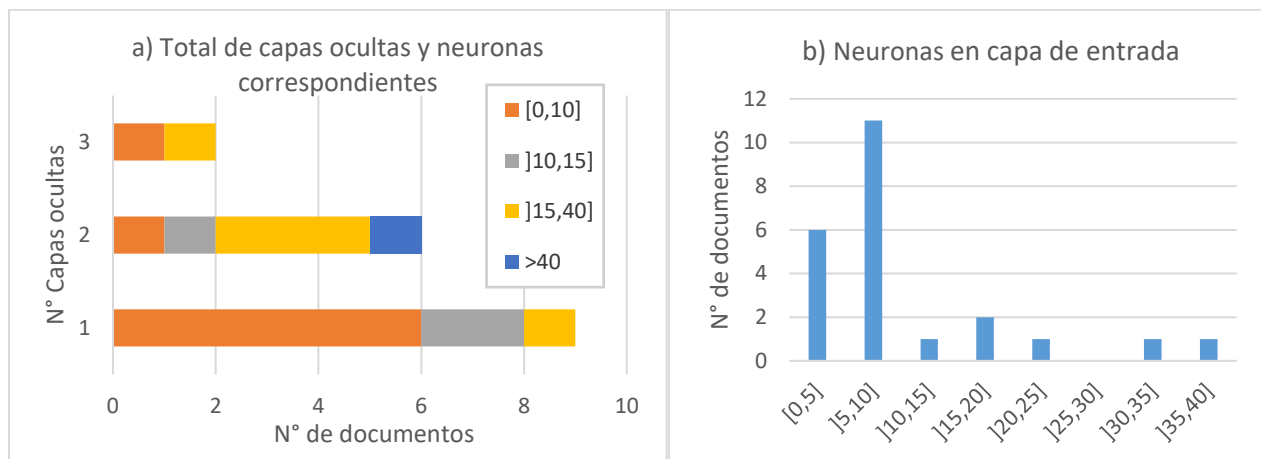


Gráfico 13: a) Total de capa(s) oculta(s) y el intervalo del total de neuronas correspondientes y b) total de variables en la capa de entrada.

Se muestra que la mayoría de los documentos necesitan sólo una capa oculta para generar el modelo, lo que concuerda con lo establecido por Georgiou et al., (2018) y, además, que la mayoría requiere entre 1 y 10 neuronas, lo cual simplifica el modelo. La mayoría de los estudios tienen entre 5 y 10 variables de entrada, lo que se considera un número apropiado para modelar el IRI teniendo en cuenta las variables más influyentes en su progresión son: IRI inicial, edad del pavimento, volumen de tránsito, precipitación anual, espesor del pavimento, granulometría, drenaje e historial de tratamientos de M&R, según Kargah-Ostadi & Stoffels, (2015).

#### 4.2.5.3 Comparación de modelos de ML

Se apartan los papers que modelen con distintas herramientas de ML y se comparan según promedio y desviación estándar de MSE,  $R^2$ ,  $r$  [%], MAE y MAPE [%],  $S_e/S_y$  y RMSE. En la TABLA 20 se encuentra el análisis estadístico de los documentos que comparan herramientas de ML, basado sólo en el coeficiente de correlación. En ANEXO E está el detalle de los documentos con los errores máximos y mínimos de los modelos.







Tabla 20: Análisis estadístico de comparación de herramientas de ML según el coeficiente de correlación.

| Análisis estadístico      | ANN    | SVM    | GP     | RF     | DT     | KNN   | NAÏVE BAYES | HYBRID | REGRESION | RNN    |
|---------------------------|--------|--------|--------|--------|--------|-------|-------------|--------|-----------|--------|
| Media                     | 0,872  | 0,910  | 0,948  | 0,892  | 0,890  | 0,880 | 0,634       | 0,957  | 0,693     | 0,900  |
| Error típico              | 0,0247 | 0,0100 | 0,0423 | 0,0658 | 0,0413 | 0     | 0           | 0,0184 | 0,0484    | 0,0254 |
| Mediana                   | 0,920  | 0,900  | 0,948  | 0,928  | 0,899  | 0,880 | 0,634       | 0,980  | 0,710     | 0,883  |
| Rango                     | 0,289  | 0,030  | 0,085  | 0,283  | 0,201  | 0     | 0           | 0,084  | 0,669     | 0,083  |
| Mínimo                    | 0,710  | 0,900  | 0,905  | 0,715  | 0,781  | 0,880 | 0,634       | 0,911  | 0,296     | 0,867  |
| Máximo                    | 0,999  | 0,930  | 0,990  | 0,998  | 0,982  | 0,880 | 0,634       | 0,994  | 0,965     | 0,950  |
| Cuenta                    | 15     | 3      | 2      | 4      | 4      | 1     | 1           | 5      | 13        | 3      |
| Nivel de confianza(95,0%) | 0,0530 | 0,0430 | 0,5368 | 0,2094 | 0,1315 | -     | -           | 0,0510 | 0,1055    | 0,1094 |

La TABLA 20 demuestra que hay muchos documentos que hacen comparación de modelos de predicción con herramientas de ML. En general los modelos híbridos son los que tienen mejores resultados, pues son optimizaciones de herramientas de ML. Son una buena opción cuando se quiere mayor precisión, pero requiere mayor desarrollo informático para generar el algoritmo. Además, las herramientas de ML, exceptuando Naïve Bayes y Regresión, tienen buena capacidad de predicción y generalización ( $R^2 > 0,87$ ). La tabla demuestra que la mayoría de los modelos son ANNs, ya que es una de las herramientas de ML más famosa debido a los alcances científicos y tecnológicos, en general se tienen modelos de redes aceptables con  $R^2$  mayores a 0,7. Los modelos de regresión se realizan principalmente para tener un punto de comparación, ya que es un modelamiento simple y rápido de obtener, con el cual se pueden lograr buenos resultados si hay suficientes datos, son multi-variables y se hace un estudio previo de los datos para ajustar la curva óptimamente.



Se debe tener en cuenta que hay muchos modelos de predicción, por lo que es difícil estimar el desempeño de un modelo simplemente comparando el coeficiente de correlación, puesto que algunos modelos pueden funcionar bien sólo para un conjunto de datos. Además, las bases de datos usadas en los documentos son distintas y, por lo tanto, las herramientas no son comparables.



#### 4.2.6 Mantenimiento y rehabilitación

Un SGP debe proporcionar herramientas para ayudar a la toma de decisiones en todos los niveles de estrategias óptimas de asignación de recursos, lo que requiere sistemas de predicción más fiables. La priorización de actividades de M&R son especialmente importante cuando hay limitaciones de tiempo y presupuesto, ya que no es posible atender a todas las secciones de la red vial en el corto plazo. En la búsqueda se encontraron documentos que predicen la estrategia de M&R más adecuada a las condiciones, puntaje de prioridad y pre-tratamiento. M&R se deben modelar con herramientas de ML eficientes y fáciles de entender, es por esto que las herramientas de ML más usadas son ANN, DT y los modelos híbridos, tal como muestra el GRÁFICO 11.

Abdelaziz et al., (2020), descubren en su estudio de predicción de IRI en pavimentos con tratamientos de mejora, que el mantenimiento que más influye a corto plazo en IRI es la superposición de concreto asfáltico. Al contrario, los que tardan en afectar son: el sellado de grietas, superficie de esmerilado, parche local de pre-mezcla manual, parche de profundidad total, parche de piel, parche de tira, capa de sellado agregada, capa de sellado lechada y capa de sellado de niebla.



## CAPÍTULO 5. ÁRBOL DE DECISIÓN Y VISUAL BASIC

### 5.1 Árbol de decisión

La(s) herramienta(s) de ML más usada(s) en modelos de deterioro de pavimentos se basa en la toma de decisiones que serán las determinantes para llegar al resultado, es por esto que se modelará mediante un DT. El árbol se forma definiendo las variables principales del problema, ordenándolas jerárquicamente, realizando un análisis estadístico en cada caso y haciendo un sistema de “si-entonces” para la toma de decisiones. Un árbol de decisión es práctico, ya que es fácil de entender, pero no es actualizable automáticamente, por lo que cada nueva situación deberá ser agregada a mano. La base de datos se asume conocida y es el punto de partida del modelo.

#### 5.1.1 Organización


El nivel jerárquico asume que la base de datos es conocida y recopilada, convirtiéndola en el punto de partida del árbol. Luego vienen los siguientes niveles:

1. ¿Hay datos históricos?: Los datos históricos corresponden a la base de datos que contiene variables independientes en varios periodos de tiempo.
2. Forma de modelamiento: Multi-variable, Serie de tiempo y Multi-variable y Serie de tiempo.
3. Tipo de Pavimento: Flexible, Rígido, No Pavimentado y Pavimento con mejora.
4. Variable de predicción: Se puede escoger sólo las variables de predicción disponibles según las elecciones tomadas en los puntos anteriores.
5. Nivel de modelamiento: Nivel de red y Nivel de proyecto, ver FIGURA 13.
6. Proyección de predicción: Basada en la simbología de la FIGURA 12.
7. Herramientas de ML (ver FIGURA 16) disponibles con su referencia correspondiente en corchetes “[ ]”.

Además, se hace un estudio estadístico de las variables en cada nivel, el cual queda representado en el árbol según colores (ver FIGURA 15). Esto ayuda en el caso de tener incertidumbres sobre el camino a tomar.

| SIMBOLOGÍA DE COLOR |         |  |
|---------------------|---------|--|
| [100-80[            | AZUL    |  |
| [80-60]             | VERDE   |  |
| ]60-40[             | NEGRO   |  |
| [40-20[             | NARANJO |  |
| [20-0]              | ROJO    |  |

Figura 15: Simbología de colores de representación estadística (porcentual) dentro del DT.



| SIMBOLOGÍA DE MODELOS |  |
|-----------------------|--|
| ANN                   | RED NEURONAL ARTIFICIAL  |
| SVM                   | MÁQUINA DE VECTOR DE SOPORTE   |
| GP                    | PROGRAMACIÓN GENÉTICA  |
| DT/RF                 | ÁRBOL DE DECISIÓN/BOSQUE ALEATORIO                                   |
| HYBRID                | MODELAMIENTO HÍBRIDO   |
| RNN                   | RED NEURONAL RECURRENTE  |
| REGRESSION            | REGRESIÓN  |
| OTRO                  | KNN: K VECINOS MÁS CERCANOS<br>NAÏVE BAYES: MODELAMIENTO NAÏVE BAYES |

Figura 16: Simbología de herramientas de ML necesaria para comprender árbol de decisión.

Finalmente, el árbol de decisión queda tal cual se ve en la FIGURA 17, el cual es segmentado para que se pueda mostrar completamente en este informe. En ANEXO F se encuentran las secciones 1.1, 1.2, 2, 3.1.1, 3.1.2 y 3.2 del árbol.

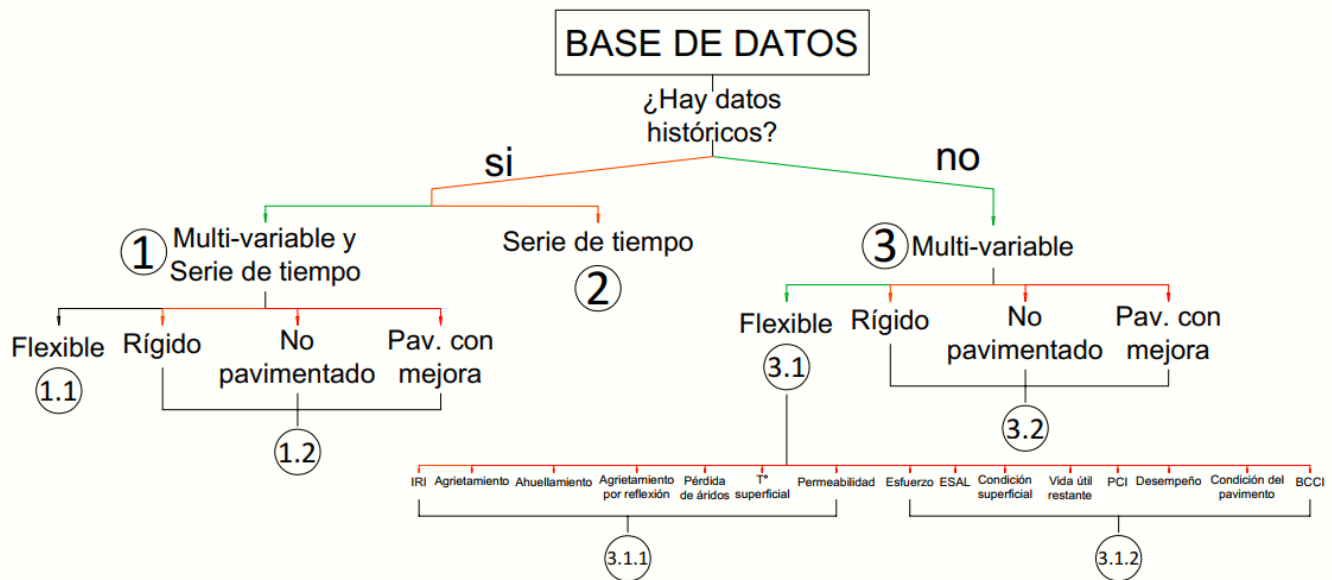




Figura 17: Estructura principal del árbol.



## 5.2 Visual Basic

El árbol de decisión es una herramienta práctica para obtener el resultado de este estudio; sin embargo, es complejo de comprender ya que las variables y condiciones son muchas. Es por esto que se desarrolló una herramienta de visualización en *Visual Basic* (VB) que convierte los resultados del árbol en una demostración gráfica basada en la toma de decisiones señaladas en *User Form* (UF - Interfaz Gráfica, en español) interconectadas.

VB es un lenguaje de programación integrado en Excel de Microsoft, como un desarrollador complemento que tiene integrada varias funciones, objetos y eventos. En total se usan 49 UFs para modelar el árbol, a las cuales se les da inicio apretando el botón “Ejecutar” presente en la hoja principal del Excel (ver FIGURA 18).

**Variables de modelamiento**

|    |                          |  |
|----|--------------------------|--|
| 1. | Hay datos históricos?    |  |
| 2. | Forma de modelamiento    |  |
| 3. | Tipo de Pavimento        |  |
| 4. | Deterioro de Predicción  |  |
| 5. | Nivel de Predicción      |  |
| 6. | Proyección de predicción |  |

**Herramienta de ML**

| Herramienta de ML | Referencia |
|-------------------|------------|
| ANN               |            |
| SVM               |            |
| GP                |            |
| DT/RF             |            |
| KNN               |            |
| NAÏVE BAYES       |            |
| HYBRID            |            |
| RNN               |            |
| REGRESSION        |            |

1  **Título:**  
**DOI/Link:**

Figura 18: Hoja principal del Excel, necesaria para dar inicio a la programación en Visual Basic.

En la parte izquierda de la hoja principal se irán completando las decisiones tomadas y a la derecha se generará el gráfico con los resultados finales presentes en la sección de la “Herramienta de ML”. En la parte inferior hay una sección de búsqueda que entrega el título del documento y su DOI o Link, para hacer más fácil encontrar los estudios de interés. Además, en la parte superior está el botón “Reiniciar” que borra todos los datos y vuelve todo el programa al inicio.

Las UF's siguen un formato típico con cuatro botones (ver FIGURA 19): dos de ellos “<<” y “>>” son para retroceder y avanzar, respectivamente, uno de “Glosario” que sirve de explicación y guía para la decisión a tomar y un botón de “Más usado” que selecciona automáticamente la alternativa estadísticamente más reproducida.



Figura 19: Formato típico de User Form, con definición de c/botón

Dentro de los Glosarios se encuentra uno para los tipos de pavimento (ver FIGURA 20), otro para la proyección de predicción (igual al de la FIGURA 12) y los correspondientes para las variables de predicción (disponibles en ANEXO G).

|                              |   |
|------------------------------|---|
| <b>Pavimento Flexible:</b>   | Pavimento con las capas superior afáltica y/o concreto afáltico, sobre base granular chancada, sub-base y subrasante. |
| <b>Pavimento Rígido:</b>     | Pavimento estructurado con una losa de hormigón o cemento en la capa superior, sobre base y/o sub-base y subrasante.  |
| <b>No pavimentado:</b>       | Pavimento de grava en su capa superior o con superficie original.   |
| <b>Pavimento con mejora:</b> | Pavimento con algun tratamiento de mantenimiento y/o rehabilitación durante su vida útil.                             |


Figura 20: Glosario de tipos de pavimentos dentro del software.

Luego de hacer todas las elecciones en el Software, el modelo generará un gráfico con los resultados presentes en la sección de Herramienta de ML. La FIGURA 21 presenta un resultado del modelo generado al escoger en todas las UF la opción “más usada”. Tener en cuenta que la sección inferior de búsqueda es manual, en la cual se debe escoger dentro de la lista el número de la referencia dentro de la sección de “Herramientas de ML”, tal como muestra el ejemplo.

### Variables de modelamiento

|    |                          |                     |
|----|--------------------------|---------------------|
| 1. | Hay datos históricos?    | No                  |
| 2. | Forma de modelamiento    | Multi-variable      |
| 3. | Tipo de Pavimento        | Flexible            |
| 4. | Variable de predicción   | IRI                 |
| 5. | Nivel de Predicción      | Nivel de Red        |
| 6. | Proyección de predicción | Predicción Completa |



| Herramienta de ML | Referencia               |
|-------------------|--------------------------|
| ANN               | [8,17,31,37,63,88,92]    |
| SVM               | [42]                     |
| GP                | [17]                     |
| DT/RF             | [31]                     |
| KNN               | -                        |
| NAÏVE BAYES       | -                        |
| HYBRID            | ANN+RF[7],<br>ANN+GP[17] |
| RNN               | [31]                     |
| REGRESSION        | [31,88,92]               |



17

**Título:** Prediction of pavement roughness using a hybrid gene expression programming-neural network technique  
**DOI/Link:** 10.1016/j.jtte.2016.09.007

*Figura 21: Ejemplo de resultado del modelo escogiendo lo más usado en cada UF.*



## CAPÍTULO 6. CONCLUSIONES Y RECOMENDACIONES

### 6.1 Conclusiones

#### 6.1.1 Conclusión General

El objetivo principal del estudio fue desarrollar una herramienta de visualización que determinara la(s) herramienta(s) de ML más efectivo(s) para el desarrollo de modelos de comportamiento de pavimentos. Para esto se desarrolló un árbol de decisión ordenado jerárquicamente según: base de datos, forma de modelamiento, tipo de pavimento, variable de predicción, nivel de modelamiento y proyección de predicción. Sin embargo, debido a la gran cantidad de estudios presentes (100 app), fue necesario buscar alguna alternativa que reflejara lo obtenido en el árbol de decisión de manera didáctica, desarrollando un software en Visual Basic de Excel.



El software proporciona una herramienta rápida y práctica para determinar las herramientas de ML desarrollados para los modelos de comportamiento de pavimentos descritos hasta diciembre del 2020. La desventaja es que, debido a que se realiza en base a un árbol de decisión, cada nuevo estudio debe ser ingresado manualmente.

#### 6.1.2 Conclusiones específicas

El árbol de decisión se obtiene desarrollando un análisis crítico de las aplicaciones de las herramientas de ML en los modelos de comportamiento de pavimentos. Para esto se hace una búsqueda completa en Scopus, limitando al uso de estudios desde 1990 a 2020.

La base de datos es obtenida principalmente de LTPP, lo que implica que es una base de datos pública completa y útil para generar modelos de predicción. Contiene datos de materiales de pavimentos, condiciones ambientales de distintas zonas climáticas, condiciones de tránsito, condiciones de construcción debido al registro de pruebas con mecanismos automáticos, historial de mantenimiento y rehabilitación, etc. También, la evaluación y recopilación de datos manual, los departamentos de transporte y la generación de datos sintética, son una buena opción para entrenar y validar los modelos.

Además, Marcelino et al., (2020), establece un método alternativo llamado Transfer Learning que ayuda a combinar la base de datos cuando no es suficiente para generar el modelo. Los datos de entrada de los modelos deben ser principalmente de las condiciones estructurales, por lo que se recomienda a las agencias de transporte tener un registro de la edad del pavimento, espesores de las capas, materialidad, etc., en conjunto con las solicitudes ambientales y de tránsito. Esto también motiva a que los modelos comiencen a desarrollarse a nivel de red y proyecto, convirtiéndose en un complemento completo para los SGP.





Se demuestra el desarrollo de modelos a corto, mediano y largo plazo. Jidong Yang et al., (2003), emplea ANNs para predecir la condición del pavimento a uno y cinco años luego del último registro, obteniendo buenos resultados a corto plazo ( $R^2 = 0,9$ ) y malos resultados a mediano plazo ( $R^2 = 0,4$ ). Posteriormente, J. Yang et al., (2006), predice el agrietamiento mediante ANNs y Cadenas de Markov Recurrente, obteniendo mejores resultados con las Cadenas de Markov a tres años; planteando que las técnicas de recurrencia son una buena alternativa para hacer predicciones a largo plazo. Tomando en cuenta esta hipótesis, Tabatabaee et al., (2013), emplea RNNs para predecir el índice de serviciabilidad PSI hasta los 14 años luego de construido el camino, tomando en cuenta las posibles mejoras en las secciones de pavimentos en estudio por el Departamento de Transporte de Minnesota y su respectiva variación en la condición.

Otras técnicas de ML también han sido desarrolladas en varios períodos de tiempo, como Marcelino et al., (2019), que predice IRI mediante un modelo de RF a 5 y 10 años usando datos de LTPP, obteniendo alta precisión con  $R^2 = 0,9$ . Además, la capacidad de generalización de las herramientas de ML puede ser mejorada mediante validación cruzada, inyección de ruido en la base de datos y algoritmos de aproximación optimizados. Estos métodos sólo son necesarios cuando se tiene una base de datos acotada y no es sencillo agregarle datos al conjunto de entrenamiento. En conclusión, las técnicas de ML son apropiadas para generar predicciones a corto o mediano plazo, como ANNs, SVM, KNN, RF, DT; y las técnicas de DL son las indicadas para predicciones a largo plazo, como RNN y su complemento LSTM. El-Diraby & Piryonosi, (2019), establecen que DT es mejor que Naïve Bayes y los modelos de regresión para incluir el impacto del cambio climático dentro del estudio.

La variable de predicción más modelada es el IRI, ya que es un indicador práctico y universal para cuantificar la rugosidad y serviciabilidad del pavimento. Por otra parte, los modelos se desarrollan principalmente mediante ANNs, ya que se dice que es la herramienta de ML más eficiente debido a que intenta imitar el funcionamiento del cerebro humano. Es por esto que se hace un estudio específico de las arquitecturas de ANNs desarrolladas en la predicción del IRI, demostrando que en la mayoría de las redes es suficiente una capa oculta para generar el modelo y que no se necesitan más de diez variables de entrada.

Lucey et al., (2019), predice rugosidad mediante dos modelos de ANN: uno que usa una estructura de Feed-Forward y Backpropagation y otro que desarrolla una red neuronal MLP, con una sección de los datos de LTPP. Ambos tienen resultados razonables y satisfactorios, basado en el coeficiente de correlación y RMSE, pero el segundo modelo obtiene resultados ligeramente mejores.

Los estudios demuestran buenos resultados al usar técnicas de ML en el desarrollo de modelos de desempeño de pavimentos. Sin embargo, es complejo hacer una conclusión general ya que son muchos los modelos de predicción y, además, hay muchos factores de los que depende el desempeño de cada modelo: la base de datos, las variables de entrada, el enfoque del modelamiento, la proyección de predicción, el nivel del modelo, etc.



La TABLA 20 evalúa la efectividad de los documentos que hacen comparación de distintas herramientas de ML usando el mismo conjunto de datos para entrenarlos y validarlos, donde se observa que los modelos híbridos tienen los mejores resultados ( $R_{prom}^2 = 0,957$ ). Por lo que se puede concluir que optimizar las herramientas de ML resulta una buena práctica cuando se quiere aumentar la precisión de los modelos, pero su desarrollo es más lento y costoso. En general, los modelos obtenidos pueden usarse con éxito en la toma de decisiones de los SGP, ya que tienen alta capacidad de generalización, precisión en la predicción y se desarrollan en un tiempo eficiente, para entrenamiento y procesamiento (Elbagalati et al., 2018).



Sylvester Inkoom et al., (2019), establece que las técnicas de Deep Learning podrían llegar a ser más precisas para desarrollar modelos de predicción del PCR a largo plazo que las técnicas de ML, debido a su alta capacidad de modelar con datos en series de tiempo y la robustez de los modelos.

Cada agencia debe tener su propio modelo de comportamiento de pavimentos, ya que cada una tiene distintas prácticas y perfiles de actividad laboral. Yamany et al., (2020), comprueba que los modelos de parámetros aleatorios son estadísticamente mejor que ANN para considerar estas singularidades; sin embargo, los modelos basados en datos con múltiples consideraciones podrían dar respuestas erróneas o no ser las más óptimas. Por lo que se recomienda que cada agencia base su modelo de deterioro en sus condiciones particulares tomando como ejemplo algún modelo ya realizado.

En la búsqueda también se encontraron documentos que predicen las estrategias de M&R más adecuada a las condiciones, puntaje de prioridad y pre-tratamiento. Hay muchas técnicas de M&R que intervienen en el pavimento, con distintas proyecciones de mejora y costos, además, la aplicación se hace más efectiva y económica cuando el pavimento no está completamente destruido. Es por esto que se requiere un SGP que ayude a la toma de decisiones eficientemente basado en modelos de deterioros fiables, en especial cuando se tienen limitaciones en tiempo y presupuesto. Los tratamientos de M&R se deben modelar con herramientas de ML eficientes y fáciles de entender, es por esto que las herramientas de ML más usadas son ANN, DT y los modelos híbridos.

## 6.2 Recomendaciones

El software de visualización determina los modelos de ML usados para determinadas condiciones, sin embargo, la herramienta más eficiente sólo podrá ser determinada mediante prueba y error. Sin embargo, debido a la cantidad de estudios disponibles, el software resulta un sistema que acota considerablemente los modelos a probar. Scikit-Learn es un código sencillo de Python que resuelve tareas de ML de manera automática (Marcelino et al., 2017), pero no obtiene resultados óptimos si no se hace un preprocesamiento de datos correcto, se escoge la herramienta de ML adecuada y no se tiene la capacidad de interpretar los resultados, lo cual se soluciona con el desarrollo de este estudio en conjunto de conocimientos de ingeniería.



A medida que el desarrollo de herramientas de ML en modelos de predicción de pavimentos avance, se pueden ir incluyendo más estudios a nivel de proyecto, pavimentos articulados dentro del estudio y más variables de predicción y entrada en los modelos, como la temperatura media anual usada en Chile para modificar el modelo empírico de la AASHTO.



Marcelino et al., (2020), propone Transfer Learning a modelos de predicción de IRI mediante Decisión Tree, Random Forest y regresión. Sin embargo, sería bueno ampliarlo a aplicación de herramientas de ML que se actualicen automáticamente y con distintas variables de predicción.

A pesar de que ML es una programación automática y que obtiene buenos resultados a problemas complejos, es preferible usarla sólo cuando la programación tradicional quede rezagada y no sea suficiente para desarrollar un modelo. Esto se debe a que ML es un proceso iterativo en el que su programa final será difícil de interpretar y depurar.

### 6.3 Desafíos dentro de la investigación:



Dentro de los documentos leídos se encuentran los siguientes vacíos:

- Los algoritmos de ML tienen buenos resultados, pero no se entiende por completo como resuelven los problemas, en especial para ANNs y herramientas de Deep Learning. Esto se denomina “problema de interpretabilidad” (Rebala et al., 2019a), que en algunos casos es igual de importante que la necesidad de resolver un problema.
- Hace falta más desarrollo en aplicaciones de herramientas de Deep Learning en modelos de deterioro, ya que son un buen candidato para generar modelos más precisos y generalizables tanto para predicciones a corto como a largo plazo. Ayudando a los SGP en estudios a nivel de proyecto y estrategias M&R, significando una buena ayuda en las tomas de decisiones.
- Incluir dentro de los modelos de desempeño mediante herramientas de ML, pavimentos con material reciclado. Deshmukh et al., (2017), propone incluir pavimentos rígidos con materiales reciclados dentro del estudio, ya que es de gran interés en países industrializados y en desarrollo para la construcción de carreteras puesto que reduce el impacto ambiental y economiza costos. En vez de producir concreto con agregados se propone usar cáscaras de coco, llantas de desecho, áridos reciclados, ladrillos triturados, etc.





## REFERENCIAS



- Abambres, M., & Ferreira, A. (2017). *Application of ANN in Pavement Engineering: State-of-Art*. <https://hal.archives-ouvertes.fr/hal-02066889>
- Abd El-Hakim, R., & El-Badawy, S. (2013). International Roughness Index Prediction for Rigid Pavements: An Artificial Neural Network Application. *Advanced Materials Research*, 723, 854-860. <https://doi.org/10.4028/www.scientific.net/AMR.723.854>
- Abdelaziz, N., Abd El-Hakim, R. T., El-Badawy, S. M., & Afify, H. A. (2020). International Roughness Index prediction model for flexible pavements. *International Journal of Pavement Engineering*, 21(1), 88-99. Scopus. <https://doi.org/10.1080/10298436.2018.1441414>
- Abiola, O. S., Owolabi, A. O., Sadiq, O. M., & Aiyedun, P. O. (2012). *APPLICATION OF DYNAMIC ARTIFICIAL NEURAL NETWORK FOR MODELLING RUTS DEPTH FOR LAGOS-IBADAN EXPRESSWAY, NIGERIA*. 7(8), 5.
- Abo-Hashema, M. A., & Sharaf, E. A. (2009). Development of maintenance decision model for flexible pavements. *International Journal of Pavement Engineering*, 10(3), 173-187. <https://doi.org/10.1080/10298430802169457>
- Alpaydin, E. (2010). *Introduction to machine learning* (2nd ed). MIT Press.
- Amin, S. R., & Amador-Jiménez, L. E. (2017). Backpropagation Neural Network to estimate pavement performance: Dealing with measurement errors. *Road Materials and Pavement Design*, 18(5), 1218-1238. <https://doi.org/10.1080/14680629.2016.1202129>
- Attoh-Okine. (1994). *PREDICTING ROUGHNESS PROGRESSION IN FLEXIBLE PAVEMENTS USING ARTIFICIAL NEURAL NETWORKS*. <http://onlinepubs.trb.org/Onlinepubs/conf/1994/cp1/cp1-v1-007.pdf>
- Attoh-Okine, N. O. (2001). Grouping Pavement Condition Variables for Performance Modeling Using Self-Organizing Maps. *Computer-Aided Civil and Infrastructure Engineering*, 16(2), 112-125. <https://doi.org/10.1111/0885-9507.00218>
- Attoh-Okine, N. O. (2005). Modeling incremental pavement roughness using functional network. *Canadian Journal of Civil Engineering*, 32(5), 899-905. <https://doi.org/10.1139/105-050>
- Bianchini, A., & Bandini, P. (2010). Prediction of Pavement Performance through Neuro-Fuzzy Reasoning: Prediction of pavement performance through neuro-fuzzy reasoning. *Computer-Aided Civil and Infrastructure Engineering*, 25(1), 39-54. <https://doi.org/10.1111/j.1467-8667.2009.00615.x>
- Bontempi, G., Ben Taieb, S., & Le Borgne, Y.-A. (2013). Machine Learning Strategies for Time Series Forecasting. En M.-A. Aufaure & E. Zimányi (Eds.), *Business Intelligence* (Vol. 138, pp. 62-77). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-642-36318-4\\_3](https://doi.org/10.1007/978-3-642-36318-4_3)
- Bosurgi, G., & Trifirò, F. (2005a). A model based on artificial neural networks and genetic algorithms for pavement maintenance management. *International Journal of Pavement Engineering*, 6(3), 201-209. <https://doi.org/10.1080/10298430500195432>





- Bosurgi, G., & Trifirò, F. (2005b). A Hybrid Approach for Pavement Maintenance Management of an Italian Motorway. *Computing in Civil Engineering (2005)*, 1-9. [https://doi.org/10.1061/40794\(179\)69](https://doi.org/10.1061/40794(179)69)
- Ceylan, H., Bayrak, M. B., & Gopalakrishnan, K. (2014). Neural Networks Applications in Pavement Engineering: A Recent Survey. *International Journal of Pavement Research and Technology*, 7(6), 434-444. [https://doi.org/10.6135/ijprt.org.tw/2014.7\(6\).434](https://doi.org/10.6135/ijprt.org.tw/2014.7(6).434)
- Ceylan, H., Gopalakrishnan, K., & Lytton, R. L. (2011). Neural Networks Modeling of Stress Growth in Asphalt Overlays due to Load and Thermal Effects during Reflection Cracking. *Journal of Materials in Civil Engineering*, 23(3), 221-229. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0000153](https://doi.org/10.1061/(ASCE)MT.1943-5533.0000153)
- Chang, J.-R., Chen, S.-H., Chen, D.-H., & Liu, Y.-B. (2008). Rutting Prediction Model Developed by Genetic Programming Method Through Full Scale Accelerated Pavement Testing. *2008 Fourth International Conference on Natural Computation*, 326-330. <https://doi.org/10.1109/ICNC.2008.673>
- Choi, J., Adams, T. M., & Bahia, H. U. (2004). Pavement Roughness Modeling Using Back-Propagation Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 19(4), 295-303. <https://doi.org/10.1111/j.1467-8667.2004.00356.x>
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Peter Campbell, J. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science and Technology*, 9(2). Scopus. <https://doi.org/10.1167/tvst.9.2.14>
- Choi, S., & Do, M. (2019). Development of the Road Pavement Deterioration Model Based on the Deep Learning Method. *Electronics*, 9(1), 3. <https://doi.org/10.3390/electronics9010003>
- Chollet, F. (2018). *Deep learning with Python*. Manning Publications Co.
- Chou, E., & Kaur, D. (1999). *Applying Neuro-Fuzzy Techniques for Intelligent Highway Pavement Performance Prediction Model*. 3.
- Department of Transportation. (2020). *Connecticut's Official State Website*. Connecticut's Official State Website. <https://portal.ct.gov/>
- Deshmukh, A., Rabbani, A., & Dhapekar, N. K. (2017). STUDY OF RIGID PAVEMENTS – REVIEW. *International Journal of Civil Engineering and Technology*, 7.
- Dong, S., Hao, P., & Tighe, S. L. (2019). A diagnostic method for evaluating the condition index of cement-stabilised base using T-S fuzzy neural network. *International Journal of Pavement Engineering*, 20(10), 1140-1153. <https://doi.org/10.1080/10298436.2017.1394097>
- Dong, Y., Shao, Y., Li, X., Li, S., Quan, L., Zhang, W., & Du, J. (2019). Forecasting Pavement Performance with a Feature Fusion LSTM-BPNN Model. *Proceedings of the 28th ACM International Conference on Information and Knowledge Management - CIKM '19*, 1953-1962. <https://doi.org/10.1145/3357384.3357867>
- Elbagalati, O., Elseifi, M. A., Gaspard, K., & Zhang, Z. (2017). Implementation of the Structural Condition Index into the Louisiana Pavement Management System Based on Rolling Wheel





- Deflectometer Testing. *Transportation Research Record: Journal of the Transportation Research Board*, 2641(1), 39-47. <https://doi.org/10.3141/2641-06>
- Elbagalati, O., Elseifi, M. A., Gaspard, K., & Zhang, Z. (2018). Development of an Enhanced Decision-Making Tool for Pavement Management Using a Neural Network Pattern-Recognition Algorithm. *Journal of Transportation Engineering, Part B: Pavements*, 144(2), 04018018. <https://doi.org/10.1061/JPEODX.0000042>
- Eldin, N. N., & Senouci, A. B. (1995a). Use of neural networks for condition rating of jointed concrete pavements. *Advances in Engineering Software*, 23(3), 133-141. [https://doi.org/10.1016/0965-9978\(95\)00077-1](https://doi.org/10.1016/0965-9978(95)00077-1)
- Eldin, N. N., & Senouci, A. B. (1995b). A Pavement Condition-Rating Model Using Backpropagation Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 10(6), 433-441. <https://doi.org/10.1111/j.1467-8667.1995.tb00303.x>
- El-Diraby, T., & Piryonesi, S. M. (2019). A Machine-Learning Solution for Quantifying the Impact of Climate Change on Roads. *CSCE Annual Conference*, 11.
- Esfandiarpour, S., & Shalaby, A. (2017). Local calibration of creep compliance models of asphalt concrete. *Construction and Building Materials*, 132, 313-322. <https://doi.org/10.1016/j.conbuildmat.2016.12.008>
- Fathi, A., Mazari, M., Saghafi, M., Hosseini, A., & Kumar, S. (2019). Parametric Study of Pavement Deterioration Using Machine Learning Algorithms. *Airfield and Highway Pavements 2019*, 31-41. <https://doi.org/10.1061/9780784482476.004>
- FDOT—Florida Department of Transportation. (2019). Florida Department of Transportation. <https://www.fdot.gov/>
- Federal Highway Administration. (2017). The Long-Term Pavement Performance Program. *Federal Highway Administration—Office of Research, Development, and Technology: Infrastructure R&D, FHWA-HRT-15-049*, 335.
- Flintsch, G. W., Zaniewski, J. P., & Delton, J. (s. f.). Artificial Neural Network for Selecting Pavement Rehabilitation Projects. *TRANSPORTATION RESEARCH RECORD*, 9.
- Fwa, T. F., & Chan, W. T. (1993). Priority Rating of Highway Maintenance Needs by Neural Networks. *Journal of Transportation Engineering*, 119(3), 419-432. [https://doi.org/10.1061/\(ASCE\)0733-947X\(1993\)119:3\(419\)](https://doi.org/10.1061/(ASCE)0733-947X(1993)119:3(419))
- Galindo, J. C. (2021). *Las empresas chinas dominarán la inteligencia artificial en 2030*. <https://www.muyinteresante.es/tecnologia/inteligencia-artificial/articulo/las-empresas-chinas-dominaran-la-inteligencia-artificial-en-2030-961525106761>
- García, G. (2017). *Introducción*. Clase 1 - Ingeniería Vial, Universidad Federico Santa María.
- Georgiou, P., Plati, C., & Loizos, A. (2018). Soft Computing Models to Predict Pavement Roughness: A Comparative Study. *Advances in Civil Engineering*, 2018. Scopus. <https://doi.org/10.1155/2018/5939806>





- Gong, H., Sun, Y., Shu, X., & Huang, B. (2018). Use of random forests regression for predicting IRI of asphalt pavements. *Construction and Building Materials*, 189, 890-897. Scopus. <https://doi.org/10.1016/j.conbuildmat.2018.09.017>
- Gong, Hongren, Sun, Y., Hu, W., & Huang, B. (2019). Neural networks for fatigue cracking prediction using outputs from pavement mechanistic-empirical design. *International Journal of Pavement Engineering*, 1-11. <https://doi.org/10.1080/10298436.2019.1580367>
- Gong, Hongren, Sun, Y., & Huang, B. (2019). Gradient Boosted Models for Enhancing Fatigue Cracking Prediction in Mechanistic-Empirical Pavement Design Guide. *Journal of Transportation Engineering, Part B: Pavements*, 145(2), 04019014. <https://doi.org/10.1061/JPEODX.0000121>
- Gong, Hongren, Sun, Y., Mei, Z., & Huang, B. (2018). Improving accuracy of rutting prediction for mechanistic-empirical pavement design guide with deep neural networks. *Construction and Building Materials*, 190, 710-718. <https://doi.org/10.1016/j.conbuildmat.2018.09.087>
- Gungor, O. E., & Al-Qadi, I. L. (2018). Developing Machine-Learning Models to Predict Airfield Pavement Responses. *Transportation Research Record: Journal of the Transportation Research Board*, 2672(29), 23-34. <https://doi.org/10.1177/0361198118780681>
- Gupta, A., Kumar, P., & Rastogi, R. (2011). *Pavement Deterioration and Maintenance Model for Low Volume Roads*. 8.
- Hafez, M., Ksaibati, K., & Atadero, R. A. (2019). Optimizing Expert-Based Decision-Making of Pavement Maintenance using Artificial Neural Networks with Pattern-Recognition Algorithms. *Transportation Research Record: Journal of the Transportation Research Board*, 2673(11), 90-100. <https://doi.org/10.1177/0361198119851085>
- Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989-993. <https://doi.org/10.1109/72.329697>
- Heidari, M. J., Najafi, A., & Alavi, S. (2018). Pavement Deterioration Modeling for Forest Roads Based on Logistic Regression. *Croat. j. for. Eng.*, 17.
- Hollmén, J., & Sirvio, K. (2011). *Forecasting Road Condition after Maintenance Works by Linear Methods and Radial Basis Function Networks* (Vol. 6792). Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-21738-8>
- 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. <https://doi.org/10.1061/JPEODX.0000088>
- Hossain, M. I., Gopiseti, L. S. P., & Miah, M. S. (2020). Artificial neural network modelling to predict international roughness index of rigid pavements. *International Journal of Pavement Research and Technology*. <https://doi.org/10.1007/s42947-020-0178-x>
- Huang, Y., & Moore, R. K. (1997). Roughness Level Probability Prediction Using Artificial Neural Networks. *Transportation Research Record: Journal of the Transportation Research Board*, 1592(1), 89-97. <https://doi.org/10.3141/1592-11>





- Inkoom, S., Sobanjo, J., Barbu, A., & Niu, X. (2019). Prediction of the crack condition of highway pavements using machine learning models. *Structure and Infrastructure Engineering*, 15(7), 940-953. Scopus. <https://doi.org/10.1080/15732479.2019.1581230>
- Inkoom, Sylvester, Sobanjo, J., Barbu, A., & Niu, X. (2019). Pavement Crack Rating Using Machine Learning Frameworks: Partitioning, Bootstrap Forest, Boosted Trees, Naïve Bayes, and K -Nearest Neighbors. *Journal of Transportation Engineering, Part B: Pavements*, 145(3), 04019031. <https://doi.org/10.1061/JPEODX.0000126>
- Jalal, M., Floris, I., & Quadrifoglio, L. (2017). *COMPUTER-AIDED PREDICTION OF PAVEMENT CONDITION INDEX (PCI) USING ANN*. 8.
- Karballaezadeh, N., Mohammadzadeh S, D., Shamshirband, S., Hajikhodaverdikhan, P., Mosavi, A., & Chau, K. (2019). Prediction of remaining service life of pavement using an optimized support vector machine (case study of Semnan–Firuzkuh road). *Engineering Applications of Computational Fluid Mechanics*, 13(1), 188-198. <https://doi.org/10.1080/19942060.2018.1563829>
- Karballaezadeh, N., Zaremotekhas, F., Shamshirband, S., Mosavi, A., Nabipour, N., Csiba, P., & Várkonyi-Kóczy, A. R. (2020). Intelligent Road Inspection with Advanced Machine Learning; Hybrid Prediction Models for Smart Mobility and Transportation Maintenance Systems. *Energies*, 13(7), 1718. <https://doi.org/10.3390/en13071718>
- Kargah-Ostadi, N. (2014). Comparison of Machine Learning Techniques for Developing Performance Prediction Models. *Computing in Civil and Building Engineering (2014)*, 1222-1229. <https://doi.org/10.1061/9780784413616.152>
- Kargah-Ostadi, N., & Stoffels, S. M. (2015). Framework for Development and Comprehensive Comparison of Empirical Pavement Performance Models. *Journal of Transportation Engineering*, 141(8), 04015012. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000779](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000779)
- Kargah-Ostadi, N., Stoffels, S. M., & Tabatabae, N. (2010). Network-Level Pavement Roughness Prediction Model for Rehabilitation Recommendations. *Transportation Research Record: Journal of the Transportation Research Board*, 2155(1), 124-133. <https://doi.org/10.3141/2155-14>
- Karlaftis, A. G., & Badr, A. (2015). Predicting asphalt pavement crack initiation following rehabilitation treatments. *Transportation Research Part C: Emerging Technologies*, 55, 510-517. <https://doi.org/10.1016/j.trc.2015.03.031>
- Kaya, O., Rezaei-Tarahomi, A., Ceylan, H., Gopalakrishnan, K., Kim, S., & Brill, D. R. (2018). Neural Network–Based Multiple-Slab Response Models for Top-Down Cracking Mode in Airfield Pavement Design. *Journal of Transportation Engineering, Part B: Pavements*, 144(2), 04018009. <https://doi.org/10.1061/JPEODX.0000035>
- Kingma, D. P., & Ba, J. (2017). Adam: A Method for Stochastic Optimization. *ArXiv:1412.6980 [Cs]*. <http://arxiv.org/abs/1412.6980>





- Kırbaş, U., & Karaşahin, M. (2016). Performance models for hot mix asphalt pavements in urban roads. *Construction and Building Materials*, 116, 281-288. <https://doi.org/10.1016/j.conbuildmat.2016.04.118>
- Kotsiantis, S. B., Kanellopoulos, D., & Pintelas, P. E. (2006). *Data Preprocessing for Supervised Learning*. 1(1), 7.
- LaDOTD. (2020). *Louisiana Department of Transportation & Development*. Connecticut's Official State Website. <http://www.dotd.la.gov/Pages/default.aspx>
- Lea, J. D., Harvey, J. T., & Tseng, E. (2014). Aggregating and Modeling Automated Pavement Condition Survey Data for Flexible Pavements for Use in Pavement Management. *Transportation Research Record: Journal of the Transportation Research Board*, 2455(1), 89-97. <https://doi.org/10.3141/2455-10>
- Li, M., & Wang, H. (2018). Prediction of Asphalt Pavement Responses from FWD Surface Deflections Using Soft Computing Methods. *Journal of Transportation Engineering, Part B: Pavements*, 144(2), 04018014. <https://doi.org/10.1061/JPEODX.0000044>
- Li, W., Huyan, J., Xiao, L., Tighe, S., & Pei, L. (2019). International roughness index prediction based on multigranularity fuzzy time series and particle swarm optimization. *Expert Systems with Applications: X*, 2, 100006. <https://doi.org/10.1016/j.eswax.2019.100006>
- Lou, Z., Gunaratne, M., Lu, J. J., & Dietrich, B. (2001). Application of neural network model to forecast short-term pavement crack condition: Florida case study. *Journal of Infrastructure Systems*, 7(4), 166-171. Scopus. [https://doi.org/10.1061/\(ASCE\)1076-0342\(2001\)7:4\(166\)](https://doi.org/10.1061/(ASCE)1076-0342(2001)7:4(166))
- Lucey, J., Fathi, A., & Mazari, M. (2019). Predicting Pavement Roughness as a Performance Indicator Using Historical Data and Artificial Intelligence. *Airfield and Highway Pavements 2019*, 10-18. <https://doi.org/10.1061/9780784482476.002>
- Marcelino, P., de Lurdes Antunes, M., Fortunato, E., & Gomes, M. C. (2017). Machine Learning for Pavement Friction Prediction Using Scikit-Learn. En E. Oliveira, J. Gama, Z. Vale, & H. Lopes Cardoso (Eds.), *Progress in Artificial Intelligence* (Vol. 10423, pp. 331-342). Springer International Publishing. [https://doi.org/10.1007/978-3-319-65340-2\\_28](https://doi.org/10.1007/978-3-319-65340-2_28)
- Marcelino, P., de Lurdes Antunes, M., Fortunato, E., & Gomes, M. C. (2020). Transfer learning for pavement performance prediction. *International Journal of Pavement Research and Technology*, 13(2), 154-167. <https://doi.org/10.1007/s42947-019-0096-z>
- Marcelino, P., Lurdes Antunes, M. de, Fortunato, E., & Castilho Gomes, M. (2019). Machine learning approach for pavement performance prediction. *International Journal of Pavement Engineering*, 1-14. <https://doi.org/10.1080/10298436.2019.1609673>
- 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. Scopus. <https://doi.org/10.1016/j.jtte.2016.09.007>
- Mazari, Mehran, & Rodriguez, D. D. (2016). A novel approach for 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.  
<https://doi.org/10.1016/j.jtte.2016.09.007>
- Muñoz, D. (2016). *Valor del Patrimonio Vial de la Red Vial Nacional-Año 2013*.  
<http://www.vialidad.cl/areasdevialidad/gestionvial/Documents/2013.pdf>
- Nabipour, N., Karballaezadeh, N., Dineva, A., Mosavi, A., Mohammadzadeh S., D., & Shamshirband, S. (2019). Comparative Analysis of Machine Learning Models for Prediction of Remaining Service Life of Flexible Pavement. *Mathematics*, 7(12), 1198.  
<https://doi.org/10.3390/math7121198>
- Najjar, Y., & Felker, V. (2006). Characterizing the Roughness Progression on Kansas Pavements: A Sequential Neuronet Approach. *GeoCongress 2006*, 1-6. [https://doi.org/10.1061/40803\(187\)127](https://doi.org/10.1061/40803(187)127)
- Nguyen, H.-L., Pham, B. T., Son, L. H., Thang, N. T., Ly, H.-B., Le, T.-T., Ho, L. S., Le, T.-H., & Tien Bui, D. (2019). Adaptive Network Based Fuzzy Inference System with Meta-Heuristic Optimizations for International Roughness Index Prediction. *Applied Sciences*, 9(21), 4715.  
<https://doi.org/10.3390/app9214715>
- Nivedya, M. K., & Mallick, R. B. (2018). Artificial neural network-based prediction of field permeability of hot mix asphalt pavement layers. *International Journal of Pavement Engineering*, 1-12.  
<https://doi.org/10.1080/10298436.2018.1519189>
- Okuda, T., Suzuki, K., & Kohtake, N. (2017). Proposal and Evaluation of Prediction of Pavement Rutting Depth by Recurrent Neural Network. *2017 6th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI)*, 1053-1054. <https://doi.org/10.1109/IIAI-AAI.2017.177>
- Oladele, A. S. (2017). Modeling a Hybrid Pavement Conditions Performance Framework for Botswana District Road Transportation Networks. *Conference: International Conference on Highway Pavements and Airfield Technology 2017*. <https://doi.org/10.1061/9780784480922.014>
- Oladele, A. S. (2013). Improved Intelligent Pavement Performance (IIPP) Modeling for Botswana District Gravel Road Networks. *Airfield and Highway Pavement 2013*, 1358-1369.  
<https://doi.org/10.1061/9780784413005.115>
- 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.  
<https://doi.org/10.1080/15732479.2017.1402064>
- Owusu-Ababio, S. (1998). Effect of Neural Network Topology on Flexible Pavement Cracking Prediction. *Computer-Aided Civil and Infrastructure Engineering*, 13(5), 349-355.  
<https://doi.org/10.1111/0885-9507.00113>
- Parvini, M. (2002). Artificial Neural Network Modeling of Pavement Performance using Expert Judgement. *Road Materials and Pavement Design*, 3(4), 373-384.  
<https://doi.org/10.1080/14680629.2002.9689931>





- Pérez, I., & Nuñez, C. (2005). El modelo HDM-4: Descripción y posibilidades de aplicación dentro de un sistema de gestión de firmes. *Universidad da Coruña. E.T.S. de Ingenieros de Caminos, Canales y Puertos*.
- Pevarello, G. (2017, abril 7). El avance científico-tecnológico de Irán frente a su complejo papel internacional. *Universidad Internacional de Valencia*.  
<https://www.universidadviu.com/es/actualidad/nuestros-expertos/el-avance-cientifico-tecnologico-de-iran-frente-su-complejo-papel>
- Pilpe Sarmiento, L. E. (2018). *Aplicación de un sistema de gestión de pavimentos urbano local a nivel de red mediante el Índice de Rugosidad Internacional (IRI) como variable de condición en la red vial del distrito de Concepción-Junín*. Universidad Continental.
- Piryonesi, M. & El-Diraby. (2017). *A data analytics solution for predicting the pavement condition index of roads using the most affordable attributes*.
- Piryonesi, S. M., & El-Diraby, T. E. (2020). Data Analytics in Asset Management: Cost-Effective Prediction of the Pavement Condition Index. *Journal of Infrastructure Systems*, 26(1), 04019036.  
[https://doi.org/10.1061/\(ASCE\)IS.1943-555X.0000512](https://doi.org/10.1061/(ASCE)IS.1943-555X.0000512)
- Qian, W. (2010). Road pavement performance evaluation model based on hybrid genetic algorithm neural network. *2010 Second International Conference on Computational Intelligence and Natural Computing*, 209-212. <https://doi.org/10.1109/CINC.2010.5643855>
- Qiu, X., Xu, W. Y., Zhang, Z. H., Li, N. N., & Hong, H. J. (2020). Surface Temperature Prediction of Asphalt Pavement Based on GBDT. *IOP Conference Series: Materials Science and Engineering*, 758, 012031. <https://doi.org/10.1088/1757-899X/758/1/012031>
- Rebala, G., Ravi, A., & Churiwala, S. (2019a). *An introduction to machine learning*. Springer Science+Business Media.
- Republic of Korea. (2017). *Korean Research Institute of Standards Science*.  
<https://www.kriss.re.kr/eng/main/main.html>
- Roberts, C. A., & Attoh-Okine, N. O. (1998). A Comparative Analysis of Two Artificial Neural Networks Using Pavement Performance Prediction. *Computer-Aided Civil and Infrastructure Engineering*, 13(5), 339-348. <https://doi.org/10.1111/0885-9507.00112>
- Rodriguez Moreno, Thenoux Zeballos, & Gonzalez Vaccarezza. (2013). *Evaluación probabilística del agrietamiento de pavimento asfáltico en carreteras de Chile*. 12(2), 14.
- Rosada, A., Arliansyah, J., & Buchari, E. (2019). Evaluation Pavement Deteriorating Condition on Surface Distress Index (SDI) Data Using Radial Basis Function Neural Networks (RBFNN). *Journal of Physics: Conference Series*, 1198(3), 032008. <https://doi.org/10.1088/1742-6596/1198/3/032008>
- Rosenblatt, F. (1957). *The perceptron a perceiving and recognizing automaton*.
- Russ, A., Mitchell, G. F., & Richardson, W. (2008). Decision Tree for Pretreatments for Winter Maintenance. *Transportation Research Record: Journal of the Transportation Research Board*, 2055(1), 106-115. <https://doi.org/10.3141/2055-13>



- Shafabakhsh, G., Talebsafa, M., Motamedi, M., & Badroodi, S. K. (2015). Analytical evaluation of load movement on flexible pavement and selection of optimum neural network algorithm. *KSCE Journal of Civil Engineering*, 19(6), 1738-1746. <https://doi.org/10.1007/s12205-014-0585-0>
- Shahnazari, H., Tutunchian, M. A., Mashayekhi, M., & Amini, A. A. (2012). Application of Soft Computing for Prediction of Pavement Condition Index. *Journal of Transportation Engineering*, 138(12), 1495-1506. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000454](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000454)
- Shalaby, A., & Reggin, A. (2007). Optimization of data collection needs for manual and automated network-level pavement condition ratings based on transverse variability and neural networks. *Canadian Journal of Civil Engineering*, 34(2), 139-146. <https://doi.org/10.1139/106-126>
- Sheng, V. S., Tada, R., & Atla, A. (2011). *An Empirical Study of Class Noise Impacts on Supervised Learning Algorithms and Measures*.
- Solminihaç, Hernan, Echaveguren, T., & Chamorro, A. (2018). *Gestión de Infraestructura Vial* (Tercera Edición). Ediciones UC.
- Tabatabaee, N., Ziyadi, M., & Shafahi, Y. (2013). Two-Stage Support Vector Classifier and Recurrent Neural Network Predictor for Pavement Performance Modeling. *Journal of Infrastructure Systems*, 19(3), 266-274. [https://doi.org/10.1061/\(ASCE\)IS.1943-555X.0000132](https://doi.org/10.1061/(ASCE)IS.1943-555X.0000132)
- Thube, D. T. (2012). Artificial Neural Network (ANN) based pavement deterioration models for low volume roads in India. *International Journal of Pavement Research and Technology*, 5(2), 115-120. Scopus.
- Tiğdemir, M. (2014). Re-Evaluation of the AASHTO-Flexible Pavement Design Equation with Neural Network Modeling. *PLoS ONE*, 9(11), e113226. <https://doi.org/10.1371/journal.pone.0113226>
- Tighe, S., Huen, K., & Haas, R. (2007). Environmental and Traffic Deterioration with Mechanistic–Empirical Pavement Design Model: Canadian Example. *Transportation Research Record: Journal of the Transportation Research Board*, 1989-2(1), 336-343. <https://doi.org/10.3141/1989-81>
- Vasquez-Varela, L. R., & García-Orozco, F. J. (2020). An overview of asphalt pavement design for streets and roads. *Revista Facultad de Ingeniería Universidad de Antioquia*. <https://doi.org/10.17533/udea.redin.20200367>
- Wang, W., Qin, Y., Li, X., Wang, D., & Chen, H. (2017). Comparisons of Faulting-Based Pavement Performance Prediction Models. *Advances in Materials Science and Engineering*, 2017, 1-9. <https://doi.org/10.1155/2017/6845215>
- Wang, X., Zhao, J., Li, Q., Fang, N., Wang, P., Ding, L., & Li, S. (2020). A Hybrid Model for Prediction in Asphalt Pavement Performance Based on Support Vector Machine and Grey Relation Analysis. *Journal of Advanced Transportation*, 2020, 1-14. <https://doi.org/10.1155/2020/7534970>
- Whiteley-Lagace, L., Helalli, K., & Dietz, J. (2011). Implementing a Pavement Management System for Low Volume Roads: Challenges and Successes. *2011 Annual Conference of the Transportation Association of Canada Edmonton, Alberta*.
- Yamany, M. S., Saeed, T. U., Volovski, M., & Ahmed, A. (2020). Characterizing the Performance of Interstate Flexible Pavements Using Artificial Neural Networks and Random Parameters



- 
- Regression. *Journal of Infrastructure Systems*, 26(2), 04020010. [https://doi.org/10.1061/\(ASCE\)IS.1943-555X.0000542](https://doi.org/10.1061/(ASCE)IS.1943-555X.0000542)
- Yan, K. Z., & Zhang, Z. (2011). Research in Analysis of Asphalt Pavement Performance Evaluation Based on PSO-SVM. *Applied Mechanics and Materials*, 97-98, 203-207. <https://doi.org/10.4028/www.scientific.net/AMM.97-98.203>
- Yang, J., Lu, J. J., Gunaratne, M., & Dietrich, B. (2006). *Modeling crack deterioration of flexible pavements: Comparison of recurrent Markov chains and artificial neural networks*. National Research Council; Scopus. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-33846855146&doi=10.3141%2f1974-05&partnerID=40&md5=d2ee74219e31f6213083a9939fcb1c23>
- Yang, Jidong, Lu, J. J., Gunaratne, M., & Xiang, Q. (2003). Forecasting Overall Pavement Condition with Neural Networks: Application on Florida Highway Network. *Transportation Research Record: Journal of the Transportation Research Board*, 1853(1), 3-12. <https://doi.org/10.3141/1853-01>
- 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: Journal of the Transportation Research Board*, 2673(1), 66-82. <https://doi.org/10.1177/0361198118822501>
- Younos, Abd El-Hakim, El-Badawy, & Afify. (2020). Multi-input performance prediction models for flexible pavements using LTPP database. *Innovative Infrastructure Solutions*, 27. <https://doi.org/10.1007/s41062-020-0275-3>
- Zhang, T., Hou, X., Li, X., Jing, H., & Zheng, B. (2009). Gradually Rolling Prediction of the Use-Level of Road Network Based on BP Neural Network. *ICCTP 2009*, 1-8. [https://doi.org/10.1061/41064\(358\)103](https://doi.org/10.1061/41064(358)103)
- Ziari, H., Maghrebi, M., Ayoubinejad, J., & Waller, S. T. (2016). Prediction of Pavement Performance: Application of Support Vector Regression with Different Kernels. *Transportation Research Record: Journal of the Transportation Research Board*, 2589(1), 135-145. <https://doi.org/10.3141/2589-15>
- Ziari, H., Sobhani, J., Ayoubinejad, J., & Hartmann, T. (2016). Prediction of IRI in short and long terms for flexible pavements: ANN and GMDH methods. *International Journal of Pavement Engineering*, 17(9), 776-788. <https://doi.org/10.1080/10298436.2015.1019498>





## ANEXOS



### ANEXO A. Representación de estudios de Bibliografía

Tabla 21: Numero de referencia de estudios, con el título, autor, año y bibliografía respectiva.



| N° | TÍTULO   | AUTOR   | AÑO  | REFERENCIA                       |
|----|--|---|------|----------------------------------|
| 1  | Transfer learning for pavement performance prediction  | Marcelino, de Lurdes Antunes, Fortunato, Gomes.       | 2020 | (Marcelino et al., 2020)         |
| 2  | Machine learning approach for pavement performance prediction  | Marcelino, Lurdes Antunes, Fortunato, Castilho Gomes. | 2019 | (Marcelino et al., 2019)         |
| 3  | Parametric study of pavement deterioration using machine learning algorithms   | Fathi, Mazari, Saghafi, Hosseini, Kumar.              | 2019 | (Fathi et al., 2019)             |
| 4  | Framework for development and comprehensive comparison of empirical pavement performance models                                | Kargah-Ostadi, Stoffels.                              | 2015 | (Kargah-Ostadi & Stoffels, 2015) |
| 5  | Comparison of machine learning techniques for developing performance prediction models   | Kargah-Ostadi.  | 2014 | (Kargah-Ostadi, 2014)            |
| 6  | Research in analysis of asphalt pavement performance evaluation based on PSO-SVM   | Yan, Zhang.   | 2011 | (Yan & Zhang, 2011)              |
| 7  | Predicting pavement roughness as a performance indicator using historical data and artificial intelligence                     | Lucey, Fathi, Mazari.                                 | 2019 | (Lucey et al., 2019)             |
| 8  | Grouping pavement condition variables for performance modeling using self-organizing maps                                      | Attoh-Okine.  | 2001 | (Attoh-Okine, 2001)              |
| 9  | Multi-input performance prediction models for flexible pavements using LTPP database   | Younos, Abd El-Hakim, El-Badawy, Afify.               | 2020 | (Younos et al., 2020)            |
| 10 | International Roughness Index prediction model for flexible pavements  | Abdelaziz, Abd El-Hakim, El-Badawy, Afify.            | 2020 | (Abdelaziz et al., 2020)         |
| 11 | Artificial neural network modelling to predict international roughness index of rigid pavements                                | Hossain, Gopiseti, Miah.                              | 2020 | (Hossain et al., 2020)           |
| 12 | International roughness index prediction based on multigranularity fuzzy time series and particle swarm optimization           | Li, Huyan, Xiao, Tighe, Pei.                          | 2019 | (W. Li et al., 2019)             |
| 13 | International roughness index prediction of flexible pavements using neural networks   | Hossain, Gopiseti, Miah.                              | 2019 | (Hossain et al., 2019)           |
| 14 | Establishment of Prediction Models of Asphalt Pavement Performance based on a Novel Data Calibration Method and Neural Network | Yao, Dong, Jiang, Ni.                                 | 2019 | (Yao et al., 2019)               |
| 16 | Comparisons of Faulting-Based Pavement Performance Prediction Models   | Wang, Qin, Li, Wang, Chen.                            | 2017 | (W. Wang et al., 2017)           |





|    |  |  |      |                                   |
|----|--|--|------|-----------------------------------|
| 17 | A novel approach for prediction of pavement roughness using a hybrid gene expression programming-neural network technique            | Mazari, Rodriguez.   | 2016 | (Mehran Mazari & Rodriguez, 2016) |
| 19 | Road pavement performance evaluation model based on hybrid genetic algorithm neural network  | Qian.  | 2010 | (Qian, 2010)                      |
| 20 | Network-level pavement roughness prediction model for rehabilitation recommendations   | Kargah-Ostadi, Stoffels, Tabatabaee.                         | 2010 | (Kargah-Ostadi et al., 2010)      |
| 21 | Artificial Neural Network Modeling of Pavement Performance using Expert Judgement  | Parvini.   | 2002 | (Parvini, 2002)                   |
| 22 | Applying neuro-fuzzy techniques for intelligent highway pavement performance prediction model  | Kaur, Chou, Eddie  | 1999 | (Chou & Kaur, 1999)               |
| 23 | A Comparative Analysis of Two Artificial Neural Networks Using Pavement Performance Prediction                                       | Roberts, Attoh-Okine.  | 1998 | (Roberts & Attoh-Okine, 1998)     |
| 24 | A Hybrid Model for Prediction in Asphalt Pavement Performance Based on Support Vector Machine and Grey Relation Analysis             | Wang, Zhao, Li, Fang, Wang, Ding, Li.                        | 2020 | (X. Wang et al., 2020)            |
| 25 | Rutting prediction model developed by genetic programming method through full scale accelerated pavement testing                     | Chang, Chen, S.-H., Chen, D.-H., Liu.                        | 2008 | (Chang et al., 2008)              |
| 26 | Development of maintenance decision model for flexible pavements   | Abo-Hashema, Sharaf.   | 2009 | (Abo-Hashema & Sharaf, 2009)      |
| 27 | Optimizing Expert-Based Decision-Making of Pavement Maintenance using Artificial Neural Networks with Pattern-Recognition Algorithms | Hafez, Ksaibati, Atadero.                                    | 2019 | (Hafez et al., 2019)              |
| 28 | A hybrid approach for pavement maintenance management of an Italian motorway   | Bosurgi, Trifirò.  | 2005 | (Bosurgi & Trifirò, 2005b)        |
| 29 | Modeling a Hybrid Pavement Conditions Performance Framework for Botswana District Road Transportation Networks                       | Oladele.   | 2017 | (Oladele, 2017)                   |
| 30 | Implementing a pavement management system for low volume roads: Challenges and successes   | Whiteley-Lagace, Helali, Dietz.                              | 2011 | (Whiteley-Lagace et al., 2011)    |
| 31 | Forecasting pavement performance with a feature fusion LSTM-BPNN model   | Dong, Li, Shao, Quan, Du, Li, Zhang.                         | 2019 | (Y. Dong et al., 2019)            |
| 32 | Improved intelligent pavement performance (IIPP) modeling for Botswana district Gravel road networks                                 | Oladele.   | 2013 | (Oladele, 2013)                   |
| 33 | Adaptive network based fuzzy inference system with meta-heuristic optimizations for international roughness index prediction         | Nguyen, Pham, Son, Thang, Ly, Le, T.-T., Ho, Le, T.-H., Bui. | 2019 | (Nguyen et al., 2019)             |
| 35 | Characterizing the roughness progression on Kansas Pavements: A sequential neuronet approach   | Najjar, Felker.  | 2006 | (Najjar & Felker, 2006)           |
| 36 | Pavement deterioration modeling for forest roads based on logistic regression and artificial neural networks                         | Heidari, Najafi, Alavi.                                      | 2018 | (Heidari et al., 2018)            |
| 37 | Artificial Neural Network (ANN) based pavement deterioration models for low volume roads in India                                    | Thube.   | 2012 | (Thube, 2012)                     |




|    |  |  |      |                                     |
|----|--|--|------|-------------------------------------|
| 38 | Surface Temperature Prediction of Asphalt Pavement Based on GBDT   | Qiu, Xu, Zhang, Li, Hong.  | 2020 | (Qiu et al., 2020)                  |
| 39 | Intelligent road inspection with advanced machine learning; Hybrid prediction models for smart mobility and transportation maintenance systems | Karballaezadeh, Zaremotekhasas, Shamshirband, Mosavi, Nabipour, Csiba, Várkonyi-Kóczy. | 2020 | (Karballaezadeh et al., 2020)       |
| 40 | Prediction of remaining service life of pavement using an optimized support vector machine (case study of Semnan–Firuzkuh road)                | Karballaezadeh, Mohammadzadeh, Shamshirband, Hajikhodaverdikhan, Mosavi, Chau.         | 2019 | (Karballaezadeh et al., 2019)       |
| 41 | Developing Machine-Learning Models to Predict Airfield Pavement Responses  | Gungor, Al-Qadi.   | 2018 | (Gungor & Al-Qadi, 2018)            |
| 42 | Prediction of pavement performance: Application of support vector regression with different kernels  | Ziari, Maghrebi, Ayoubinejad, Waller.  | 2016 | (Ziari, Maghrebi, et al., 2016)     |
| 44 | Data Analytics in Asset Management: Cost-Effective Prediction of the Pavement Condition Index  | Piryonesi, El-Diraby.  | 2020 | (S. M. Piryonesi & El-Diraby, 2020) |
| 45 | Comparative analysis of machine learning models for prediction of remaining service life of flexible pavement                                  | Nabipour, Karballaezadeh, Dineva, Mosavi, Mohammadzadeh, Shamshirband.                 | 2019 | (Nabipour et al., 2019)             |
| 46 | Prediction of the crack condition of highway pavements using machine learning models   | Inkoom, Sobanjo, Barbu, Niu.   | 2019 | (S. Inkoom et al., 2019)            |
| 47 | Gradient Boosted Models for Enhancing Fatigue Cracking Prediction in Mechanistic-Empirical Pavement Design Guide                               | Gong, Sun, Huang.  | 2019 | (Hongren Gong, Sun, & Huang, 2019)  |
| 48 | A machine-learning solution for quantifying the impact of climate change on roads  | Piryonesi, El-Diraby.  | 2019 | (El-Diraby & Piryonesi, 2019)       |
| 50 | Improving accuracy of rutting prediction for mechanistic-empirical pavement design guide with deep neural networks                             | Gong, Sun, Mei, Huang.   | 2018 | (Hongren Gong et al., 2018)         |
| 51 | Artificial neural network-based prediction of field permeability of hot mix asphalt pavement layers  | Nivedya, Mallick.  | 2018 | (Nivedya & Mallick, 2018)           |
| 52 | Machine learning for pavement friction prediction using scikit-learn   | Marcelino, de Lurdes Antunes, Fortunato, Gomes.  | 2017 | (Marcelino et al., 2017)            |
| 53 | Re-evaluation of the AASHTO-flexible pavement design equation with neural network modeling   | Tigdemir.  | 2014 | (Tigdemir, 2014)                    |
| 54 | Two-stage support vector classifier and recurrent neural network predictor for pavement performance modeling                                   | Tabatabaee, Ziyadi, Shafahi.   | 2013 | (Tabatabaee et al., 2013)           |
| 55 | Proposal and Evaluation of Prediction of Pavement Rutting Depth by Recurrent Neural Network  | Okuda, Suzuki, Kohtake.  | 2017 | (Okuda et al., 2017)                |



|    |  |  |      |                                       |
|----|--|--|------|---------------------------------------|
| 56 | Modeling crack deterioration of flexible pavements: Comparison of recurrent Markov chains and artificial neural networks             | Yang, Lu, Gunaratne, Dietrich.                             | 2006 | (J. Yang et al., 2006)                |
| 57 | Development of the road pavement deterioration model based on the deep learning method   | Choi, Do.  | 2020 | (S. Choi & Do, 2019)                  |
| 58 | Evaluation Pavement Deteriorating Condition on Surface Distress Index (SDI) Data Using Radial Basis Function Neural Networks (RBFNN) | Rosada, Arliansyah, Buchari.                               | 2019 | (Rosada et al., 2019)                 |
| 59 | Prediction of asphalt pavement responses from FWD surface deflections using soft computing methods                                   | Li, Wang.  | 2018 | (M. Li & Wang, 2018)                  |
| 60 | Development of an enhanced decision-making tool for pavement management using a neural network pattern-recognition algorithm         | Elbagalati, Elseifi, Gaspard, Zhang.                       | 2018 | (Elbagalati et al., 2018)             |
| 61 | Computer-aided prediction of Pavement Condition Index (PCI) using ANN  | Jalal, Floris, Quadrifoglio.                               | 2017 | (Jalal et al., 2017)                  |
| 62 | Performance models for hot mix asphalt pavements in urban roads  | Kırbaş, Karaşahin.   | 2016 | (Kırbaş & Karaşahin, 2016)            |
| 63 | Prediction of IRI in short and long terms for flexible pavements: ANN and GMDH methods   | Ziari, Sobhani, Ayoubinejad, Hartmann.                     | 2015 | (Ziari, Sobhani, et al., 2016)        |
| 64 | International roughness index prediction for rigid pavements: An Artificial Neural Network Application                               | Abd El-Hakim, El-Badawy.                                   | 2013 | (Abd El-Hakim & El-Badawy, 2013)      |
| 65 | Application of soft computing for prediction of pavement condition index   | Shahnazari, Tutunchian, Mashayekhi, Amini.                 | 2012 | (Shahnazari et al., 2012)             |
| 66 | Prediction of pavement performance through neuro-fuzzy reasoning   | Bianchini, Bandini.  | 2010 | (Bianchini & Bandini, 2010)           |
| 67 | Forecasting Overall Pavement Condition with Neural Networks: Application on Florida Highway Network                                  | Yang, Lu, Gunaratne, Xiang.                                | 2003 | (Jidong Yang et al., 2003)            |
| 68 | Roughness level probability prediction using artificial neural networks  | Huang, Moore.  | 1997 | (Huang & Moore, 1997)                 |
| 70 | Neural networks for fatigue cracking prediction using outputs from pavement mechanistic-empirical design                             | Gong, Sun, Hu, Huang.                                      | 2019 | (Hongren Gong, Sun, Hu, et al., 2019) |
| 71 | A diagnostic method for evaluating the condition index of cement-stabilized base using T-S fuzzy neural network                      | Dong, Hao, Tighe.  | 2019 | (S. Dong et al., 2019)                |
| 72 | Neural network-based multiple-slab response models for top-down cracking mode in airfield pavement design                            | Kaya, Rezaei-Tarahomi, Ceylan, Gopalakrishnan, Kim, Brill. | 2018 | (Kaya et al., 2018)                   |
| 73 | Local calibration of creep compliance models of asphalt concrete   | Esfandiarpour, Shalaby.                                    | 2017 | (Esfandiarpour & Shalaby, 2017)       |




|    |   |   |      |                                  |
|----|---|---|------|----------------------------------|
| 74 | Analytical evaluation of load movement on flexible pavement and selection of optimum neural network algorithm   | Shafabakhsh, Talebsafa, Motamedi, Badroodi. | 2015 | (Shafabakhsh et al., 2015)       |
| 75 | Predicting asphalt pavement crack initiation following rehabilitation treatments  | Karlaftis, Badr.                            | 2015 | (Karlaftis & Badr, 2015)         |
| 77 | Neural Networks Modeling of Stress Growth in Asphalt Overlays due to Load and Thermal Effects during Reflection Cracking                                    | Ceylan, Gopalakrishnan, Lytton.             | 2011 | (Ceylan et al., 2011)            |
| 79 | Effect of Neural Network Topology on Flexible Pavement Cracking Prediction  | Owusu-Ababio.                               | 1998 | (Owusu-Ababio, 1998)             |
| 80 | Backpropagation Neural Network to estimate pavement performance: dealing with measurement errors  | Amin, Amador-Jiménez.                       | 2017 | (Amin & Amador-Jiménez, 2017)    |
| 81 | Pavement deterioration and maintenance model for low volume roads   | Gupta, Kumar, Rastogi.                      | 2011 | (Gupta et al., 2011)             |
| 82 | Optimization of data collection needs for manual and automated network-level pavement condition ratings based on transverse variability and neural networks | Shalaby, Reggin.                            | 2007 | (Shalaby & Reggin, 2007)         |
| 84 | Artificial neural network for selecting pavement rehabilitation projects  | Flintsch, Zaniewski, Delton.                | 1996 | (Flintsch et al., s. f.)         |
| 85 | Use of neural networks for condition rating of jointed concrete pavements   | Eldin, Senouci.                             | 1995 | (Eldin & Senouci, 1995a)         |
| 86 | A Pavement Condition-Rating Model Using Backpropagation Neural Networks   | Eldin, Senouci.                             | 1995 | (Eldin & Senouci, 1995b)         |
| 87 | Priority rating of highway maintenance needs by neural networks   | Fwa, Chan.                                  | 1993 | (Fwa & Chan, 1993)               |
| 88 | Characterizing the Performance of Interstate Flexible Pavements Using Artificial Neural Networks and Random Parameters Regression                           | Yamany, Saeed, Volovski, Ahmed.             | 2020 | (Yamany et al., 2020)            |
| 89 | Soft Computing Models to Predict Pavement Roughness: A Comparative Study  | Georgiou, Plati, Loizos.                    | 2018 | (Georgiou et al., 2018)          |
| 90 | Application of dynamic artificial neural network for modelling ruts depth for Lagos-Ibadan Expressway, Nigeria  | Abiola, Owolabi, Sadiq, Aiyedun.            | 2012 | (Abiola et al., 2012)            |
| 91 | Modeling incremental pavement roughness using functional network  | Attoh-Okine.                                | 2005 | (Attoh-Okine, 2005)              |
| 92 | Pavement roughness modeling using back-propagation neural networks  | Choi, Adams, Bahia.                         | 2004 | (J. Choi et al., 2004)           |
| 93 | Application of neural network model to forecast short-term pavement crack condition: Florida case study   | Lou, Gunaratne, Lu, Dietrich.               | 2001 | (Lou et al., 2001)               |
| 94 | Implementation of the structural condition index into the Louisiana pavement management system based on rolling wheel deflectometer testing                 | Elbagalati, Elseifi, Gaspard, Zhang.        | 2017 | (Elbagalati et al., 2017)        |
| 95 | A data analytics solution for predicting the condition of roads using the most affordable attributes  | Piryonesi, El-Diraby.                       | 2017 | (M. Piryonesi & El-Diraby, 2017) |



---



|            |   |                                  |      |                                 |
|------------|---|----------------------------------|------|---------------------------------|
| <b>96</b>  | Aggregating and modeling automated pavement condition survey data for flexible pavements for use in pavement management                       | Lea, Harvey, Tseng.              | 2014 | (Lea et al., 2014)              |
| <b>97</b>  | Decision tree for pretreatments for winter maintenance  | Russ, Mitchell, Richardson.      | 2008 | (Russ et al., 2008)             |
| <b>98</b>  | Use of random forests regression for predicting IRI of asphalt pavements  | Gong, Sun, Shu, Huang.           | 2018 | (H. Gong et al., 2018)          |
| <b>99</b>  | Pavement Crack Rating Using Machine Learning Frameworks: Partitioning, Bootstrap Forest, Boosted Trees, Naïve Bayes, and K -Nearest Neighbors | Inkoom, Sobanjo, Barbu, Niu.     | 2019 | (Sylvester Inkoom et al., 2019) |
| <b>100</b> | Gradually rolling prediction of the use-level of road network based on BP neural network  | Zhang, Hou, Li.-K., Jing, Zheng. | 2009 | (Zhang et al., 2009)            |
| <b>101</b> | A model based on artificial neural networks and genetic algorithms for pavement maintenance management  | Bosurgi, Trifirò.                | 2005 | (Bosurgi & Trifirò, 2005a)      |





ANEXO B. Conjunto de variables de entrada en función de la variable de predicción

Tabla 22: Conjunto de variable de entrada en función de la variable de predicción, para pavimento flexible.

| OUTPUT                 |    | INPUT                |                       |                       |                           |                            | N° | REFERENCIA    |                                 |
|------------------------|----|----------------------|-----------------------|-----------------------|---------------------------|----------------------------|----|---------------|---------------------------------|
| Variable de predicción |    | Condiciones de clima | Condición de tránsito | Condición estructural | Condición de construcción | Historial de mantenimiento |    |               |                                 |
| IRI                    | 24 | 3                    | 3                     | 3                     |                           |                            | 3  | [1] [21] [63] |                                 |
|                        |    | 1                    | 1                     |                       |                           |                            | 1  | [57]          |                                 |
|                        |    | 1                    |                       | 1                     |                           |                            | 1  | [88]          |                                 |
|                        |    | 1                    | 1                     | 1                     | 1                         | 1                          | 1  | [5]           |                                 |
|                        |    |                      | 4                     | 4                     |                           |                            |    | 4             | [7] [13] [68] [92]              |
|                        |    | 7                    | 7                     | 7                     | 7                         |                            |    | 7             | [2] [4] [8] [31] [37] [91] [98] |
|                        |    |                      |                       | 1                     | 1                         |                            |    | 1             | [10]                            |
|                        |    |                      | 1                     | 1                     | 1                         |                            |    | 1             | [17]                            |
|                        |    |                      |                       |                       | 2                         |                            |    | 2             | [33] [89]                       |
|                        |    | 1                    | 1                     | 1                     |                           |                            | 1  | 1             | [42]                            |
|                        |    |                      | 2                     |                       |                           | 2                          |    | 2             | [12] [23]                       |
|                        | 14 | 20                   | 19                    | 14                    | 2                         |                            |    |               |                                 |
| PCI                    | 10 | 1                    | 1                     | 1                     |                           |                            | 1  | [9]           |                                 |
|                        |    | 1                    | 1                     | 1                     |                           | 1                          | 1  | [48]          |                                 |
|                        |    |                      | 2                     | 2                     | 2                         |                            |    | 2             | [44] [80]                       |
|                        |    |                      | 2                     | 2                     |                           |                            |    | 2             | [61] [65]                       |
|                        |    | 1                    |                       | 1                     |                           |                            |    | 1             | [95]                            |
|                        |    |                      |                       | 3                     |                           |                            |    | 3             | [6] [39] [62]                   |
| PSI                    | 2  | 3                    | 6                     | 10                    | 2                         | 1                          |    |               |                                 |
|                        |    |                      | 1                     |                       | 1                         |                            | 1  | 1             | [66]                            |
|                        |    | 1                    | 1                     | 1                     | 1                         | 1                          | 1  | 1             | [54]                            |
| Desempeño              | 2  | 1                    | 2                     | 1                     | 2                         | 1                          |    |               |                                 |
|                        |    | 1                    | 1                     | 1                     | 1                         |                            | 1  | 1             | [19]                            |
|                        |    |                      | 1                     | 1                     |                           |                            | 1  | 1             | [24]                            |
|                        | 1  | 2                    | 2                     | 1                     | 1                         |                            |    |               |                                 |





|                             |    |   |   |   |   |   |   |                |
|-----------------------------|----|---|---|---|---|---|---|----------------|
| Condición superficial       | 2  | 1 |   |   |   |   | 1 | [30]           |
|                             |    | 1 |   |   |   |   | 1 | [58]           |
|                             |    | 0 | 0 | 2 | 1 | 1 |   |                |
| Ahuellamiento               | 7  | 3 | 3 | 3 | 3 |   | 3 | [36] [37] [50] |
|                             |    | 2 |   |   |   |   | 2 | [55] [90]      |
|                             |    | 1 |   |   |   |   | 1 | [57]           |
|                             |    | 1 |   |   |   |   | 1 | [25]           |
|                             |    | 4 | 7 | 6 | 5 | 2 |   |                |
| Baches                      | 1  | 1 |   |   |   |   | 1 | [36]           |
|                             |    | 1 | 1 | 1 | 1 | 0 |   |                |
| Condición del pavimento     | 4  | 1 |   |   |   |   | 1 | [60]           |
|                             |    | 1 |   |   |   |   | 1 | [94]           |
|                             |    | 2 |   |   |   |   | 2 | [67] [86]      |
|                             |    | 0 | 1 | 4 | 3 | 1 |   |                |
| Número de Fricción          | 1  | 1 |   |   |   |   | 1 | [52]           |
|                             |    | 1 | 1 | 0 | 1 | 0 |   |                |
| Esfuerzo                    | 3  | 1 |   |   |   |   | 1 | [73]           |
|                             |    | 1 | 1 | 1 | 1 |   | 1 | [59]           |
|                             |    | 1 |   |   |   |   | 1 | [100]          |
|                             |    | 1 | 1 | 2 | 2 | 0 |   |                |
| ESAL                        | 1  | 1 |   |   |   |   | 1 | [53]           |
|                             |    | 1 | 0 | 1 | 1 | 0 |   |                |
| Agrietamiento               | 11 | 3 | 3 | 3 | 3 |   | 3 | [37] [47] [70] |
|                             |    | 1 |   |   |   |   | 1 | [57]           |
|                             |    | 1 |   |   |   |   | 1 | [93]           |
|                             |    | 3 |   |   |   |   | 3 | [46] [56] [99] |
|                             |    | 1 | 1 | 1 |   | 1 | 1 | [75]           |
|                             |    | 1 |   |   |   |   | 1 | [79]           |
|                             |    | 1 |   |   |   |   | 1 | [3]            |
| Agrietamiento por reflexión | 1  | 1 |   |   |   |   | 1 | [74]           |
|                             |    | 0 | 1 | 1 | 0 | 0 |   |                |



|                    |   |   |   |   |   |   |      |
|--------------------|---|---|---|---|---|---|------|
| Pérdida de árido   | 1 | 1 | 1 | 1 | 1 | 1 | [37] |
|                    |   | 1 | 1 | 1 | 1 | 0 |      |
| Permeabilidad      | 1 | 1 |   |   | 1 | 1 | [51] |
|                    |   | 0 | 0 | 1 | 0 | 0 |      |
| T° Superficial     | 1 | 1 |   |   | 1 | 1 | [38] |
|                    |   | 1 | 0 | 0 | 0 | 0 |      |
| Vida útil restante | 2 | 1 |   |   | 1 | 1 | [40] |
|                    |   | 1 |   |   | 1 | 1 | [45] |
|                    |   | 1 | 0 | 2 | 0 | 0 |      |
| BCCI               | 1 | 1 | 1 | 1 | 1 | 1 | [71] |
|                    |   | 1 | 1 | 1 | 1 | 0 |      |

Tabla 23: Conjunto de variable de entrada en función de la variable de predicción, para pavimento rígido.

| OUTPUT                 |    | INPUT                |                       |                       |                        |                            | N° | REFERENCIA   |           |
|------------------------|----|----------------------|-----------------------|-----------------------|------------------------|----------------------------|----|--------------|-----------|
| Variable de predicción |    | Condiciones de clima | Condición de tránsito | Condición estructural | Método de construcción | Historial de mantenimiento |    |              |           |
| IRI                    | 13 | 3                    | 3                     | 3                     | 3                      |                            | 3  | [2] [8] [31] |           |
|                        |    |                      | 1                     | 1                     |                        |                            | 1  | [7]          |           |
|                        |    |                      | 1                     |                       |                        | 1                          |    | 1            | [12]      |
|                        |    |                      | 1                     | 1                     | 1                      | 1                          |    | 1            | [17]      |
|                        |    | 1                    | 1                     | 1                     |                        |                            |    | 1            | [21]      |
|                        |    |                      |                       |                       |                        | 2                          |    | 2            | [33] [89] |
|                        |    | 2                    | 2                     |                       |                        |                            |    | 2            | [11] [57] |
|                        |    | 1                    | 1                     | 1                     |                        |                            | 1  | 1            | [35]      |
|                        |    | 1                    |                       | 1                     | 1                      |                            |    | 1            | [64]      |
| PCI                    | 2  | 8                    | 10                    | 8                     | 8                      | 1                          |    |              |           |
|                        |    |                      | 1                     | 1                     | 1                      |                            | 1  | [80]         |           |
|                        |    |                      | 1                     | 1                     |                        |                            | 1  | [61]         |           |
|                        |    | 0                    | 2                     | 2                     | 1                      | 0                          |    |              |           |



|                         |   |   |   |   |   |   |           |
|-------------------------|---|---|---|---|---|---|-----------|
| Desempeño               | 2 | 1 | 1 | 1 | 1 | 1 | [19]      |
|                         |   | 1 |   | 1 |   | 1 | [41]      |
|                         |   | 2 | 1 | 2 | 1 | 0 |           |
| Condición superficial   | 2 |   |   | 1 |   | 1 | [30]      |
|                         |   |   |   | 1 | 1 |   | [58]      |
|                         |   | 0 | 0 | 2 | 1 | 1 |           |
| Condición del pavimento | 3 |   |   | 2 |   |   | [82] [85] |
|                         |   |   |   | 1 | 1 |   | [67]      |
|                         |   | 0 | 0 | 3 | 1 | 0 |           |
| Esfuerzos               | 1 |   | 1 | 1 |   |   | [72]      |
|                         |   | 0 | 1 | 1 | 0 | 0 |           |
| Agrietamiento           | 2 | 1 | 1 |   |   |   | [57]      |
|                         |   |   |   | 1 | 1 |   | [93]      |
|                         |   | 1 | 1 | 1 | 1 | 0 |           |
| T° Superficial          | 1 | 1 |   | 1 |   |   | [47]      |
|                         |   | 1 | 0 | 1 | 0 | 0 |           |
| Falla de Junta          | 1 | 1 | 1 | 1 |   |   | [16]      |
|                         |   | 1 | 1 | 1 | 0 | 0 |           |

Tabla 24: Conjunto de variable de entrada en función de la variable de predicción, para camino no pavimentado.

| OUTPUT                 |   | INPUT                |                       |                       |                        |                            | N°   | REFERENCIA |
|------------------------|---|----------------------|-----------------------|-----------------------|------------------------|----------------------------|------|------------|
| Variable de predicción |   | Condiciones de clima | Condición de tránsito | Condición estructural | Método de construcción | Historial de mantenimiento |      |            |
| Condición superficial  | 1 |                      |                       | 1                     |                        | 1                          | [30] |            |
|                        |   | 0                    | 0                     | 1                     | 0                      | 1                          |      |            |
| Pérdida de árido       | 2 | 1                    | 1                     | 1                     |                        |                            | [29] |            |
|                        |   |                      | 1                     | 1                     | 1                      |                            | [32] |            |
|                        |   | 1                    | 2                     | 2                     | 1                      | 0                          |      |            |







Tabla 25: Conjunto de variable de entrada en función de la variable de predicción, para pavimento con mejora.

| OUTPUT                      |   | INPUT                |                       |                       |                        |                            | N° | REFERENCIA |      |
|-----------------------------|---|----------------------|-----------------------|-----------------------|------------------------|----------------------------|----|------------|------|
| Variable de predicción      |   | Condiciones de clima | Condición de tránsito | Condición estructural | Método de construcción | Historial de mantenimiento |    |            |      |
| IRI                         | 4 |                      |                       | 1                     | 1                      |                            | 1  | [10]       |      |
|                             |   | 1                    | 1                     | 1                     |                        | 1                          | 1  | [42]       |      |
|                             |   |                      | 1                     | 1                     | 1                      | 1                          | 1  | 1          | [14] |
|                             |   | 1                    | 1                     | 1                     | 1                      | 1                          | 1  | 1          | [20] |
|                             |   | 2                    | 3                     | 4                     | 3                      | 3                          |    |            |      |
| PCI                         | 1 | 1                    | 1                     | 1                     |                        | 1                          | 1  | [48]       |      |
|                             |   | 1                    | 1                     | 1                     | 0                      | 1                          |    |            |      |
| PSI                         | 1 | 1                    | 1                     | 1                     | 1                      | 1                          | 1  | [54]       |      |
|                             |   | 1                    | 1                     | 1                     | 1                      | 1                          |    |            |      |
| Desempeño                   | 1 |                      | 1                     | 1                     |                        | 1                          | 1  | [24]       |      |
|                             |   | 0                    | 1                     | 1                     | 0                      | 1                          |    |            |      |
| Ahuellamiento               | 1 |                      | 1                     | 1                     | 1                      | 1                          | 1  | [14]       |      |
|                             |   | 0                    | 1                     | 1                     | 1                      | 1                          |    |            |      |
| Condición del Pavimento     | 1 |                      | 1                     | 1                     | 1                      | 1                          | 1  | [14]       |      |
|                             |   | 0                    | 1                     | 1                     | 1                      | 1                          |    |            |      |
| Agrietamiento               | 1 |                      | 1                     | 1                     | 1                      | 1                          | 1  | [14]       |      |
|                             |   | 0                    | 1                     | 1                     | 1                      | 1                          |    |            |      |
| Agrietamiento por reflexión | 1 |                      |                       | 1                     |                        |                            | 1  | [77]       |      |
|                             |   | 0                    | 0                     | 1                     | 0                      | 0                          |    |            |      |
| Coef de fuerza lateral      | 3 |                      | 1                     | 1                     | 1                      | 1                          | 1  | [14]       |      |
|                             |   |                      | 1                     | 1                     |                        |                            |    | 1          | [28] |
|                             |   | 1                    | 1                     | 1                     | 1                      |                            | 1  | [101]      |      |
|                             |   | 1                    | 3                     | 3                     | 2                      | 1                          |    |            |      |



ANEXO C. División de base de datos en sub-conjunto de entrenamiento, validación y prueba



Tabla 26: Subconjuntos de base de datos para obtener algoritmos de modelación, según herramientas de ML

| Herramienta de ML | Sub-conjuntos de base de datos |            |        | Contador | REFERENCIA   |
|-------------------|--------------------------------|------------|--------|----------|--|
|                   | Entrenamiento                  | Validación | Prueba |          |  |
| ANN               | ✓                              | ✓          |        | 15       | [34] [79] [16] [17] [29] [33] [46] [54] [74] [77] [79] [85] [86] [88] [91]   |
|                   | ✓                              |            | ✓      | 12       | [50] [55] [8] [13.1] [20] [23] [40] [43] [64] [68] [82] [84]   |
|                   | ✓                              | ✓          | ✓      | 26       | [36] [4] [5] [9] [10] [11] [13.2] [14] [27] [35] [37] [51] [53] [60] [61] [62] [63] [65] [70] [72] [73] [80] [87] [89] [92] [93] |
| SVM               | ✓                              | ✓          |        | 2        | [54] [89]  |
|                   | ✓                              |            | ✓      | 2        | [40] [45]  |
|                   | ✓                              | ✓          | ✓      | 3        | [4] [5] [41]   |
| GP                | ✓                              | ✓          |        | 2        | [25] [17]  |
|                   | ✓                              |            | ✓      | 1        | [45]   |
|                   | ✓                              | ✓          | ✓      | 2        | [25] [65]  |
| DT                | ✓                              | ✓          |        | 3        | [26] [38] [46]   |
|                   | ✓                              |            | ✓      | 1        | [47]   |
| RF                | ✓                              | ✓          |        | 2        | [38] [99]  |
|                   | ✓                              |            | ✓      | 2        | [2] [98]   |
| KNN               | ✓                              | ✓          |        | 1        | [99]   |
| NAÏVE BAYES       | ✓                              | ✓          |        | 1        | [99]   |
| HYBRID            | ✓                              | ✓          |        | 4        | [17] [33] [59] [66]  |
|                   | ✓                              |            | ✓      | 3        | [28] [45] [101]  |
|                   | ✓                              | ✓          | ✓      | 8        | [3] [4] [5] [6] [7] [12] [71] [75]   |
| RNN               | ✓                              |            | ✓      | 3        | [31] [50] [57]   |
| REGRESSION        | ✓                              | ✓          |        | 3        | [34] [16] [38]   |
|                   | ✓                              |            | ✓      | 3        | [50] [55] [68]   |
|                   | ✓                              | ✓          | ✓      | 5        | [36] [9] [10] [73] [92]  |



ANEXO D. Herramienta de ML para cada variable de predicción

Tabla 27: Herramienta de ML para cada variable de predicción según tipo de pavimento



| Pavimento Flexible      | PREDICCIÓN | TOT         | Herramienta ML           | Referencia   | N° |
|-------------------------|------------|-------------|--------------------------|--|----|
|                         | IRI        | 43          | ANN                      | [4] [5] [8] [10] [12] [13] [17] [21] [23] [31] [33] [37] [63] [68] [88] [89] [91] [92] | 18 |
|                         |            |             | SVM                      | [4] [5] [42] [89]  | 4  |
|                         |            |             | GP                       | [17]   | 1  |
|                         |            |             | RF                       | [1] [2] [98]   | 3  |
|                         |            |             | DT                       | [1] [31]   | 2  |
|                         |            |             | NAÏVE BAYES              | [21]   | 1  |
|                         |            |             | HYBRID                   | [7] [12] [17] [33]   | 4  |
|                         |            |             | RNN                      | [31] [57]  | 2  |
|                         |            |             | REGRESSION               | [1] [10] [12] [31] [68] [88] [92] [98]   | 8  |
| PCI                     | 14         | ANN         | [9] [39] [61] [62]       | 4  |    |
|                         |            | RF          | [48]                     | 1  |    |
|                         |            | DT          | [44] [48]                | 2  |    |
|                         |            | KNN         | [48]                     | 1  |    |
|                         |            | NAÏVE BAYES | [48]                     | 1  |    |
|                         |            | HYBRID      | [6] [39]                 | 2  |    |
|                         |            | REGRESSION  | [9] [48] [62]            | 3  |    |
| PSI                     | 5          | ANN         | [54]                     | 1  |    |
|                         |            | SVM         | [54]                     | 1  |    |
|                         |            | HYBRID      | [54] [66]                | 2  |    |
|                         |            | REGRESSION  | [66]                     | 1  |    |
| Desempeño               | 4          | ANN         | [19]                     | 1  |    |
|                         |            | HYBRID      | [19] [24]                | 2  |    |
|                         |            | REGRESSION  | [24]                     | 1  |    |
| Condición superficial   | 3          | ANN         | [58]                     | 1  |    |
|                         |            | DT          | [30]                     | 1  |    |
|                         |            | REGRESSION  | [58]                     | 1  |    |
| Ahuellamiento           | 13         | ANN         | [36] [37] [50] [55] [90] | 5  |    |
|                         |            | GP          | [25]                     | 1  |    |
|                         |            | RF          | [57]                     | 1  |    |
|                         |            | HYBRID      | [57]                     | 1  |    |
|                         |            | RNN         | [50] [57]                | 2  |    |
|                         |            | REGRESSION  | [36] [50] [55]           | 3  |    |
| Baches                  | 2          | ANN         | [36]                     | 1  |    |
|                         |            | REGRESSION  | [36]                     | 1  |    |
| Condición del pavimento | 4          | ANN         | [60] [67] [86]           | 3  |    |
|                         |            | DT          | [94]                     | 1  |    |




| PREDICCIÓN                  |                    | TOT        | Herramienta ML | Referencia                    | N° |
|-----------------------------|--------------------|------------|----------------|-------------------------------|----|
| Pavimento Flexible          | Número de Fricción | 1          | REGRESSION     | [52]                          | 1  |
|                             | Esfuerzos          | 4          | ANN            | [73] [100]                    | 2  |
|                             |                    |            | HYBRID         | [59]                          | 1  |
|                             |                    |            | REGRESSION     | [73]                          | 1  |
|                             | ESAL               | 2          | ANN            | [53]                          | 1  |
|                             |                    |            | REGRESSION     | [53]                          | 1  |
|                             | Agrietamiento      | 17         | ANN            | [37] [46] [56] [70] [79] [93] | 6  |
|                             |                    |            | RF             | [3] [99]                      | 2  |
|                             |                    |            | DT             | [46] [47] [99]                | 3  |
|                             |                    |            | KNN            | [99]                          | 1  |
|                             |                    |            | NAÏVE BAYES    | [99]                          | 1  |
|                             |                    |            | HYBRID         | [3] [75]                      | 2  |
|                             |                    |            | RNN            | [57]                          | 1  |
| REGRESSION                  | [99]               | 1          |                |                               |    |
| Agrietamiento por reflexión | 1                  | ANN        | [74]           | 1                             |    |
| Pérdida de árido            | 1                  | ANN        | [37]           | 1                             |    |
| Permeabilidad               | 1                  | ANN        | [51]           | 1                             |    |
| T° superficial              | 3                  | RF         | [38]           | 1                             |    |
|                             |                    | DT         | [38]           | 1                             |    |
|                             |                    | REGRESSION | [38]           | 1                             |    |
| Vida útil restante          | 6                  | ANN        | [40]           | 1                             |    |
|                             |                    | SVM        | [40] [45]      | 2                             |    |
|                             |                    | GP         | [45]           | 1                             |    |
|                             |                    | HYBRID     | [40] [45]      | 2                             |    |
| BCCI                        | 1                  | HYBRID     | [71]           | 1                             |    |



|                                | <b>PREDICCIÓN</b>            | <b>TOT</b> | <b>Herramienta ML</b> | <b>Referencia</b>                                   | <b>N°</b> |
|--------------------------------|------------------------------|------------|-----------------------|---|-----------|
| <b>Pavimento Rígido</b>        | <b>IRI</b>                   | 23         | ANN                   | [8] [11] [12] [17] [21] [31] [33] [35]<br>[64] [89] | 10        |
|                                |                              |            | SVM                   | [89]  | 1         |
|                                |                              |            | GP                    | [17]  | 1         |
|                                |                              |            | RF                    | [2]   | 1         |
|                                |                              |            | DT                    | [31]  | 1         |
|                                |                              |            | NAÏVE BAYES           | [21]  | 1         |
|                                |                              |            | HYBRID                | [7] [12] [17] [33]                                  | 4         |
|                                |                              |            | RNN                   | [31] [57]   | 2         |
|                                |                              |            | REGRESSION            | [12] [31]   | 2         |
|                                | <b>PCI</b>                   | 2          | ANN                   | [61] [80]   | 2         |
|                                | <b>Desempeño</b>             | 3          | ANN                   | [19]  | 1         |
|                                |                              |            | SVM                   | [41]  | 1         |
|                                |                              |            | HYBRID                | [19]  | 1         |
|                                | <b>Condición superficial</b> | 3          | ANN                   | [58]  | 1         |
| DT                             |                              |            | [30]                  | 1   |           |
| REGRESSION                     |                              |            | [58]                  | 1   |           |
| <b>Condición del pavimento</b> | 3                            | ANN        | [67] [82] [85]        | 3   |           |
| <b>Esfuerzos</b>               | 1                            | ANN        | [72]                  | 1   |           |
| <b>Agrietamiento</b>           | 2                            | ANN        | [93]                  | 1   |           |
|                                |                              | RNN        | [57]                  | 1   |           |
| <b>T° superficial</b>          | 1                            | SVM        | [41]                  | 1   |           |
| <b>Falla de junta</b>          | 2                            | ANN        | [16]                  | 1   |           |
|                                |                              | REGRESSION | [16]                  | 1   |           |
| <b>No Pav.</b>                 | <b>Condición Superficial</b> | 1          | DT                    | [30]  | 1         |
|                                | <b>Pérdida de árido</b>      | 3          | ANN                   | [29] [32]   | 2         |
|                                |                              |            | REGRESSION            | [32]  | 1         |



| Pavimento con mejora        | PREDICCIÓN | TOT        | Herramienta ML | Referencia     | N° |
|-----------------------------|------------|------------|----------------|----------------|----|
|                             | IRI        | 5          | ANN            | [10] [14] [20] | 3  |
|                             |            |            | SVM            | [42]           | 1  |
|                             |            |            | REGRESSION     | [10]           | 1  |
|                             | PCI        | 5          | RF             | [48]           | 1  |
|                             |            |            | DT             | [48]           | 1  |
|                             |            |            | KNN            | [48]           | 1  |
|                             |            |            | NAÏVE BAYES    | [48]           | 1  |
|                             |            |            | REGRESSION     | [48]           | 1  |
|                             | PSI        | 3          | ANN            | [54]           | 1  |
| SVM                         |            |            | [54]           | 1              |    |
| HYBRID                      |            |            | [54]           | 1              |    |
| Desempeño                   | 2          | HYBRID     | [24]           | 1              |    |
|                             |            | REGRESSION | [24]           | 1              |    |
| Ahuellamiento               | 1          | ANN        | [14]           | 1              |    |
| Condición del pavimento     | 1          | ANN        | [14]           | 1              |    |
| Agrietamiento               | 1          | ANN        | [14]           | 1              |    |
| Agrietamiento por reflexión | 1          | ANN        | [77]           | 1              |    |
| Coef de fuerza Lat.         | 3          | ANN        | [14] [28]      | 2              |    |
|                             |            | GP         | [101]          | 1              |    |



ANEXO E. Comparación de modelos

Tabla 28: Documentos encontrados con comparación de modelos de ML.

| Referencia | ANN | SVM | GP | RF | DT | KNN | NAÏVE BAYES | HYBRID | REGRESSION | RNN |
|------------|-----|-----|----|----|----|-----|-------------|--------|------------|-----|
| 1          |     |     |    | x  | x  |     |             |        | x          |     |
| 3          |     |     |    | x  |    |     |             | x      |            |     |
| 4          | x   | x   |    |    |    |     |             |        | x          |     |
| 5          | x   | x   |    |    |    |     |             |        |            |     |
| 10         | x   |     |    |    |    |     |             |        | x          |     |
| 12         | x   |     |    |    |    |     |             | x      | x          |     |
| 16         | x   |     |    |    |    |     |             |        | x          |     |
| 17         | x   |     | x  |    |    |     |             | x      |            |     |
| 19         | x   |     |    |    |    |     |             | x      |            |     |
| 21         | x   |     |    |    |    |     | x           |        |            |     |
| 24         |     |     |    |    |    |     |             | x      | x          |     |
| 31         | x   |     |    |    | x  |     |             | x      | x          |     |
| 32         | x   |     |    |    |    |     |             |        | x          |     |
| 33         | x   |     |    |    |    |     |             | x      |            |     |
| 36         | x   |     |    |    |    |     |             |        | x          |     |
| 38         |     |     |    | x  | x  |     |             |        | x          |     |
| 39         | x   |     |    |    |    |     |             | x      |            |     |
| 40         | x   | x   |    |    |    |     |             | x      |            |     |
| 45         |     | x   | x  |    |    |     |             | x      |            |     |
| 46         | x   |     |    |    | x  |     |             |        |            |     |
| 48         |     |     |    | x  | x  | x   | x           |        | x          |     |
| 50         | x   |     |    |    |    |     |             |        | x          |     |
| 53         | x   |     |    |    |    |     |             |        | x          |     |
| 54         |     |     |    |    |    |     |             | x      |            | x   |
| 55         | x   |     |    |    |    |     |             |        | x          | x   |
| 58         | x   |     |    |    |    |     |             |        | x          |     |
| 62         | x   |     |    |    |    |     |             |        | x          |     |
| 65         | x   |     | x  |    |    |     |             |        |            |     |
| 66         |     |     |    |    |    |     |             | x      | x          |     |
| 73         | x   |     |    |    |    |     |             |        | x          |     |
| 88         | x   |     |    |    |    |     |             |        | x          |     |
| 89         | x   | x   |    |    |    |     |             |        |            |     |
| 92         | x   |     |    |    |    |     |             |        | x          |     |
| 98         |     |     |    | x  |    |     |             |        | x          |     |
| 99         |     |     |    | x  | x  | x   | x           |        | x          |     |







Tabla 29: Tabla comparativa de herramientas de ML con errores mayores y menores respectivamente..


| Referencia | MSE prom                     | Desv estándar MSE            | R <sup>2</sup>                      | r [%]                          | MAE y MAPE[%]*                    | Se/Sy                         | RMSE                                       |
|------------|------------------------------|------------------------------|-------------------------------------|--------------------------------|-----------------------------------|-------------------------------|--|
| 1          | -                            | -                            | RF(UV/LT)=0,817<br>RF(MV/ST)= 0,998 | -                              | -                                 | -                             | -  |
| 3          | -                            | -                            | RF=0,64<br>RF-ANN=0,92              | -                              | -                                 | -                             | RF-ANN=8,4<br>RF=15,66                     |
| 4          | ANN-BR=0,007<br>NL-REG=0,039 | ANN-BR=0,012<br>NL-REG=0,023 | ANN-ES &<br>GSVM=0,9<br>ANN-BR=0,94 | -                              | -                                 | -                             | -  |
| 5          | -                            | -                            | G-SVM=0,90<br>FF-ANN-BR=0,94        | -                              | -                                 | -                             | -  |
| 10         | -                            | -                            | REGRESIÓN=0,57<br>ANN=0,75          | -                              | -                                 | ANN=0,660<br>REGRESSION=0,684 | -  |
| 12         | -                            | -                            | -                                   | -                              | Multigran=6,37%<br>Polynom=12,33% | -                             | Multigran=0,191<br>Polynom=0,366           |
| 16         | -                            | -                            | -                                   | -                              | MC=1,37<br>MNLR=3,34              | -                             | MC=1,7<br>MNLR=3,86                        |
| 17         | -                            | -                            | GEP-ANN=0,9941<br>GEP=0,9053        | -                              | -                                 | -                             | -  |
| 19         | -                            | -                            | -                                   | -                              | -                                 | -                             | GA-NN(4-10-1)=0,0019<br>ANN(4-15-1)=0,0062 |
| 24         | -                            | -                            | -                                   | GM(1,1)=0,856<br>GRA-SVR=0,992 | GRA-SVR=-0,081<br>PPI=-4,569      | -                             | GRA-SVR=0,298<br>PPI=3,270                 |
| 31         | -                            | -                            | LSTM-BPNN=0,865<br>LR=0,738         | -                              | -                                 | -                             | LSTM-BPNN=0,242<br>BPNN=0,353              |
| 32         | -                            | -                            | MLR=0,74<br>FFNN=0,94               | -                              | -                                 | -                             | -  |



| Referencia | MSE prom                              | Desv estándar MSE                 | R <sup>2</sup>                           | r [%]                          | MAE y MAPE[%]*                  | Se/Sy | RMSE                                  |
|------------|---------------------------------------|-----------------------------------|--|--------------------------------|---------------------------------|-------|---------------------------------------|
| 33         | ANN=0,000<br>PSO-ANFIS=0,004          | PSO-ANFIS=0,122<br>ANN=0,200      | ANN=0,806<br>PSO-ANFIS=0,933             | ANN=0,806<br>PSO-ANFIS=0,933   | -                               | -     | PSOANFIS=0,122<br>ANN=0,200           |
| 36         | -                                     | -                                 | -  | -                              | -                               | -     | ANN(BACHES)=0,194<br>LR(BACHES)=0,253 |
|            | -                                     | -                                 | -  | -                              | -                               | -     | ANN(RUT)=0,207<br>LR(RUT)=0,265       |
|            | -                                     | -                                 | -  | -                              | -                               | -     | ANN(CRACK)=0,168<br>LR(CRACK)=0,244   |
| 38         | GBDT<1,5<br>LR=4,1                    | -                                 | -  | -                              | -                               | -     | -                                     |
| 39         | MLP-<br>LM=0,02115%<br>RBF-GA=14,300% | CMIS=0,021081<br>RBF-ICA=0,134177 | -  | -                              | CMIS=11,6768<br>RBF-ICA=15,276% | -     | CMIS=12,0056<br>RBF-GA=28,74778       |
| 40         | SVR-PF=0,02<br>SVM=ANN=0,11           | -                                 | -  | SVM=46<br>SVR-PF=95            | -                               | -     | SVR-PF=0,14<br>ANN=SVM=0,33           |
| 45         | -                                     | -                                 | -  | SVR=0,865<br>SVR-<br>FOA=0,879 | -                               | -     | -                                     |
| 46         | -                                     | -                                 | DT=0,9<br>ANN=0,92                       | -                              | ANN=0,35<br>DT=0,34             | -     | ANN=0,54<br>DT=0,52                   |
| 50         | -                                     | -                                 | MLR3,<br>MLR20<0,265<br>ANN3,ANN20>0,472 | -                              | -                               | -     | -                                     |
| 53         | -                                     | -                                 | MLR=0,68<br>ANN=0,976                    | -                              | -                               | -     | -                                     |
| 54         | -                                     | -                                 | RNN=0,95<br>SVC-RNN=0,98                 | -                              | -                               | -     | SVC-RNN=0,135<br>RNN=0,272            |



| Referencia | MSE prom                 | Desv estándar MSE                  | R <sup>2</sup>                        | r [%]                | MAE y MAPE[%]*                      | Se/Sy                     | RMSE                                 |
|------------|--------------------------|------------------------------------|---------------------------------------|----------------------|-------------------------------------|---------------------------|--------------------------------------|
| 55         | -                        | -                                  | -                                     | -                    | -                                   | -                         | RNN=2,27<br>MLR=2,52                 |
| 58         | ANN=0,002<br>RL mayor    | -                                  | RL=0,69<br>ANN=0,82                   | -                    | -                                   | -                         | -                                    |
| 62         | -                        | -                                  | Determ. REG=0,71<br>ANN=0,7465        | -                    | -                                   | -                         | -                                    |
| 65         | -                        | -                                  | GP=0,9887<br>ANN=0,9986               | -                    | ANN=0,52<br>GP=1,60                 | -                         | ANN=0,72<br>GP=2,03                  |
| 66         | -                        | -                                  | MLR= 0,85592<br>ANN-<br>FUZZY=0,94534 | -                    | ANN-<br>FUZZY=0,07826<br>MLR=0,2044 | -                         | ANN-FUZZY= 0,11418<br>MLR = 0,27326  |
| 73         | -                        | -                                  | RNL MV=0,830<br>ANN=0,874             | -                    | -                                   | ANN=0,357<br>RNL MV=0,421 | -                                    |
| 88         | ANN=0,0707<br>Reg=0,0894 | ANN=0,285[m/km]<br>Reg=0,385[m/km] | Reg=0,48<br>ANN=0,71                  | -                    | ANN=18,79 [%]<br>Reg=24,44 [%]      | -                         | ANN=0,2659[m/km]<br>Reg=0,2991[m/km] |
| 89         | -                        | -                                  | SVM=0,93<br>ANN=0,94                  | -                    | ANN=7,8 [%]<br>SVM=8,2 [%]          | -                         | ANN=9,6[%]<br>SVM=9,9[%]             |
| 92         | ANN=0,025<br>MLR=0,277   | -                                  | -                                     | MLR=0,46<br>ANN=0,87 | -                                   | -                         | -                                    |
| 98         | RF=0,0005<br>RL=0,0859   | -                                  | RL=0,625<br>RF=0,998                  | -                    | -                                   | -                         | -                                    |
| 99         | -                        | -                                  | BAYES=0,634<br>KNN(K=2)=0,923         | -                    | KNN=0,191<br>MLR=0,441              | -                         | -                                    |



ANEXO F. Árbol de decisión

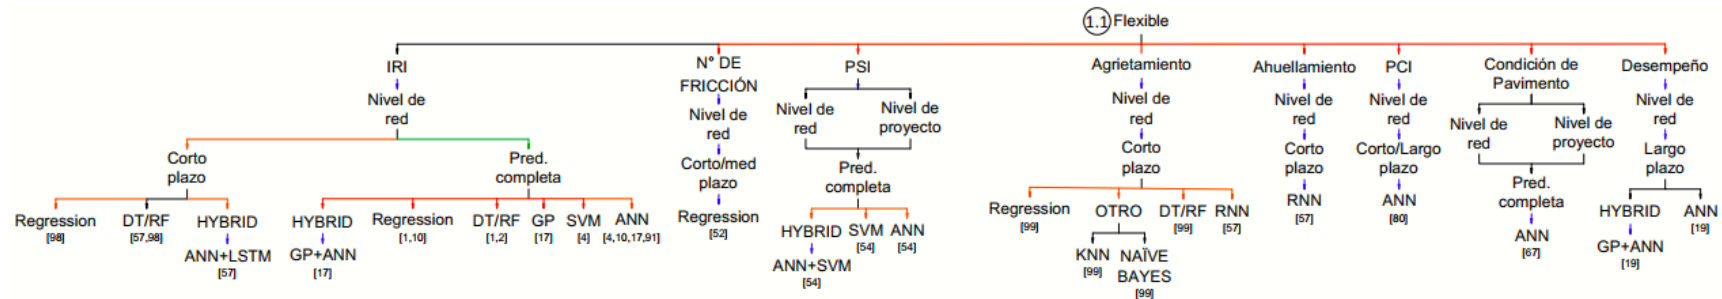


Figura 22: Sección 1.1 del árbol de decisión, correspondiente a los pavimentos flexibles del modelamiento mixto.

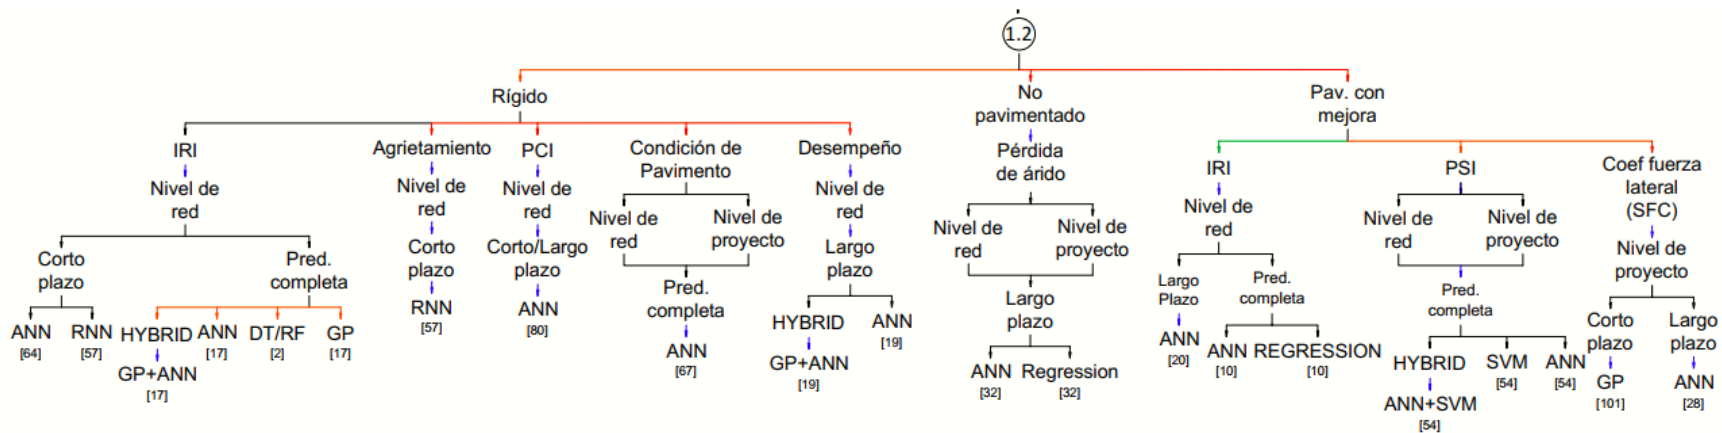


Figura 23: Sección 1.2 del árbol de decisión, correspondiente a los pavimentos rígidos, caminos no pavimentados y pavimentos con mejora del modelamiento mixto.

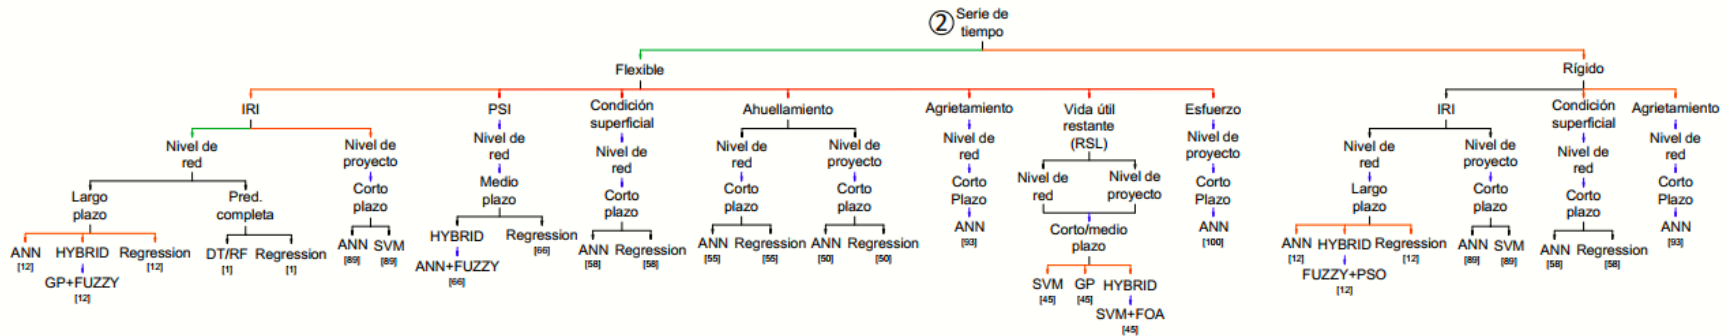



Figura 24: Sección 2 del árbol de decisión, correspondiente al modelamiento en serie de tiempo.

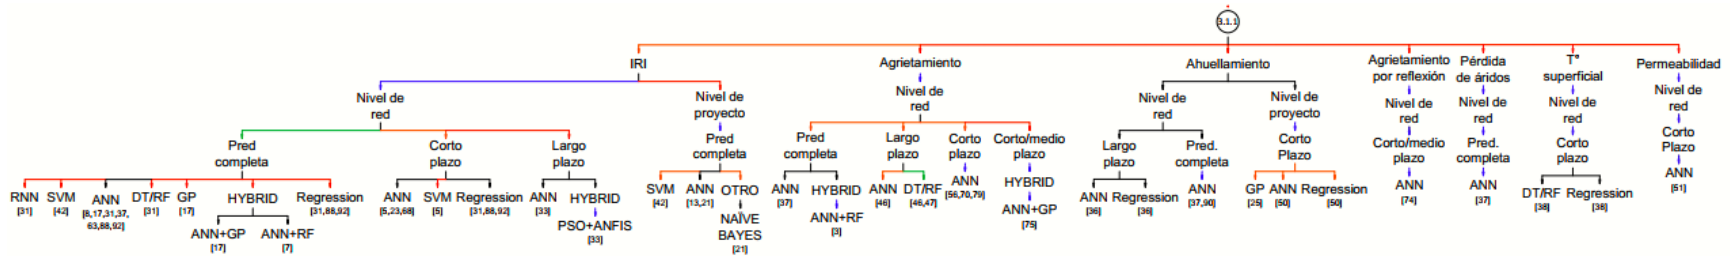


Figura 25: Sección 3.1.1 del árbol de decisión, correspondiente al IRI, Agrietamiento, Ahuellamiento, Agrietamiento por reflexión, Pérdida de áridos,  $T^*$  superficial y permeabilidad de pavimentos flexibles del modelamiento multi-variable.




Figura 26: Sección 3.1.1 del árbol de decisión, correspondiente al Esfuerzo, ESAL, Condición superficial, Vida útil restante, PCI, Desempeño, Condición del pavimento y BCCI de pavimentos flexibles del modelamiento multi-variable.






Figura 27: Sección 3.2 del árbol de decisión, correspondiente a los pavimentos rígidos y pavimentos con mejora del modelamiento multi-variable.

## ANEXO G. Visual Basic

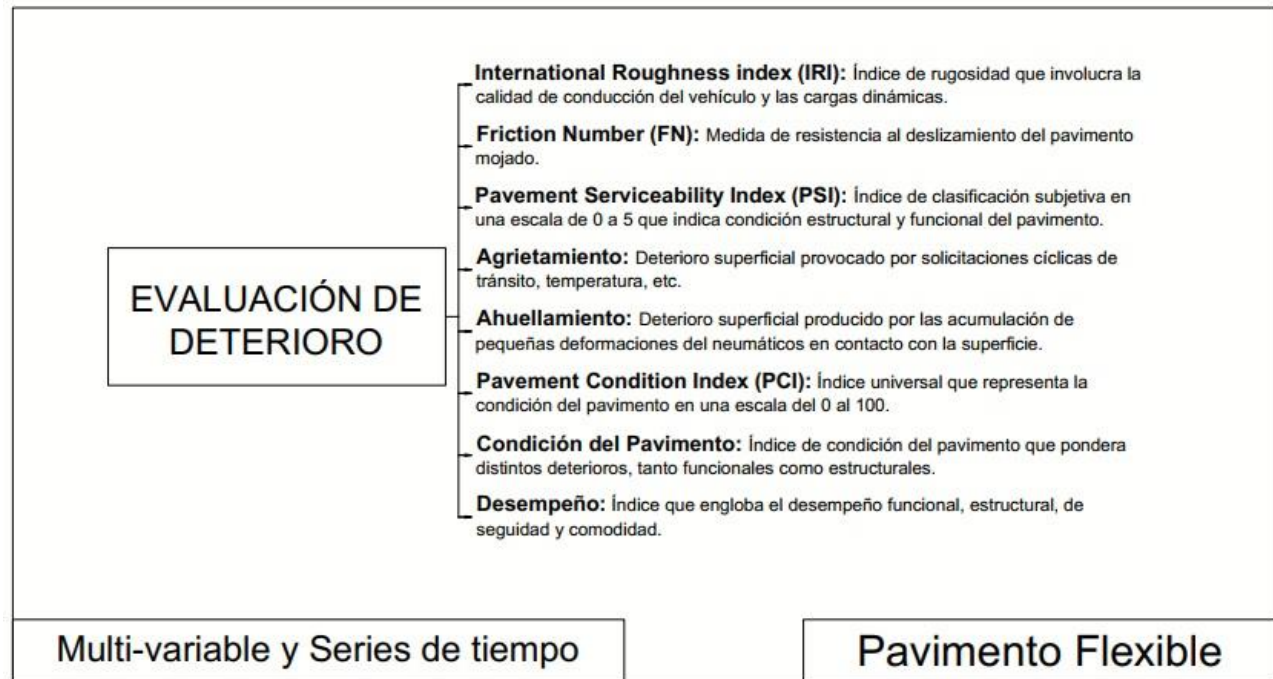


Figura 28: Glosario de variable de predicción para pavimentos flexibles, con enfoque de modelamiento mixto.

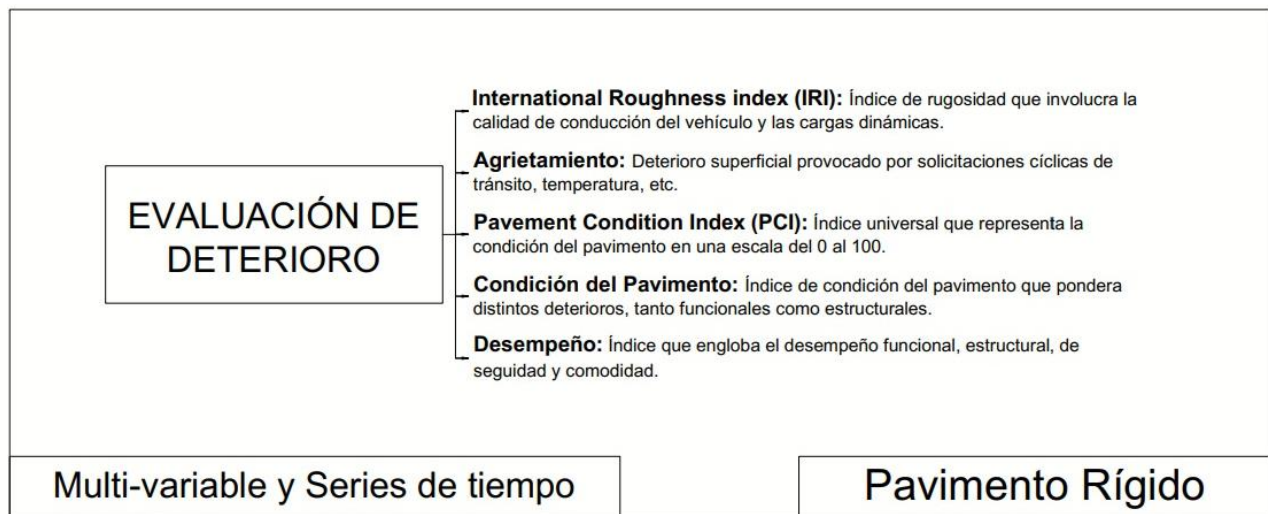


Figura 29: Glosario de variable de predicción para pavimentos rígidos, con enfoque de modelamiento mixto.




Figura 30: Glosario de variable de predicción para pavimentos con mejora, con enfoque de modelamiento mixto.



Figura 31: Glosario de variable de predicción para pavimentos flexibles, con enfoque de modelamiento en series de tiempo.

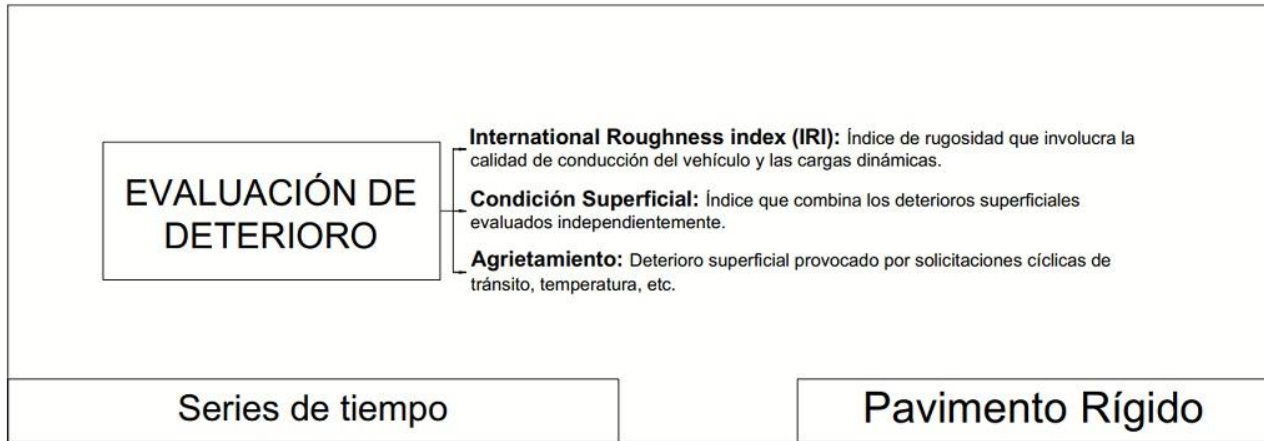



Figura 32: Glosario de variable de predicción para pavimentos rígidos, con enfoque de modelamiento en series de tiempo.

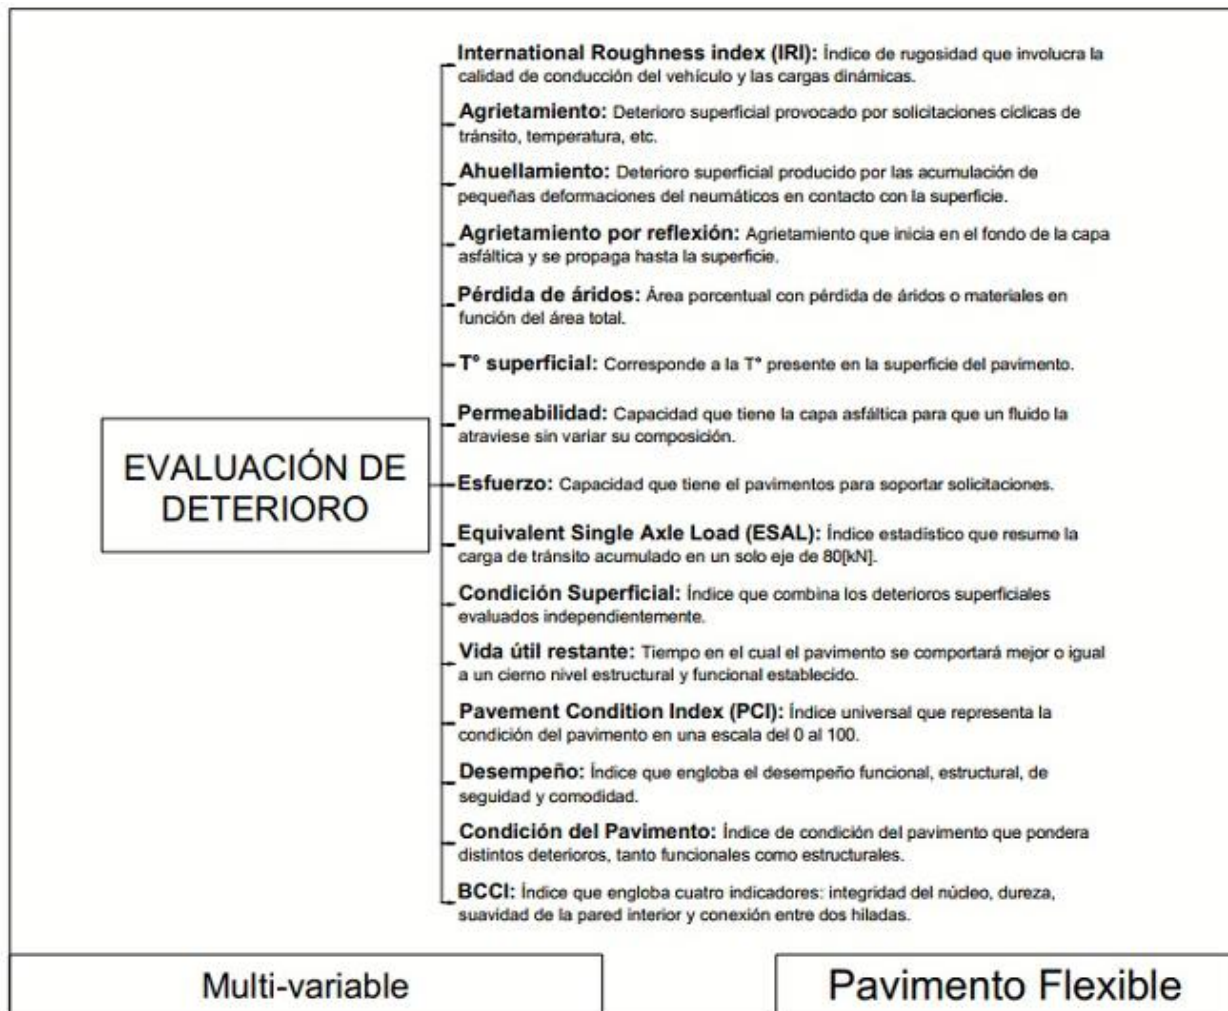


Figura 33: Glosario de variable de predicción para pavimentos flexibles, con enfoque de modelamiento multi-variable.

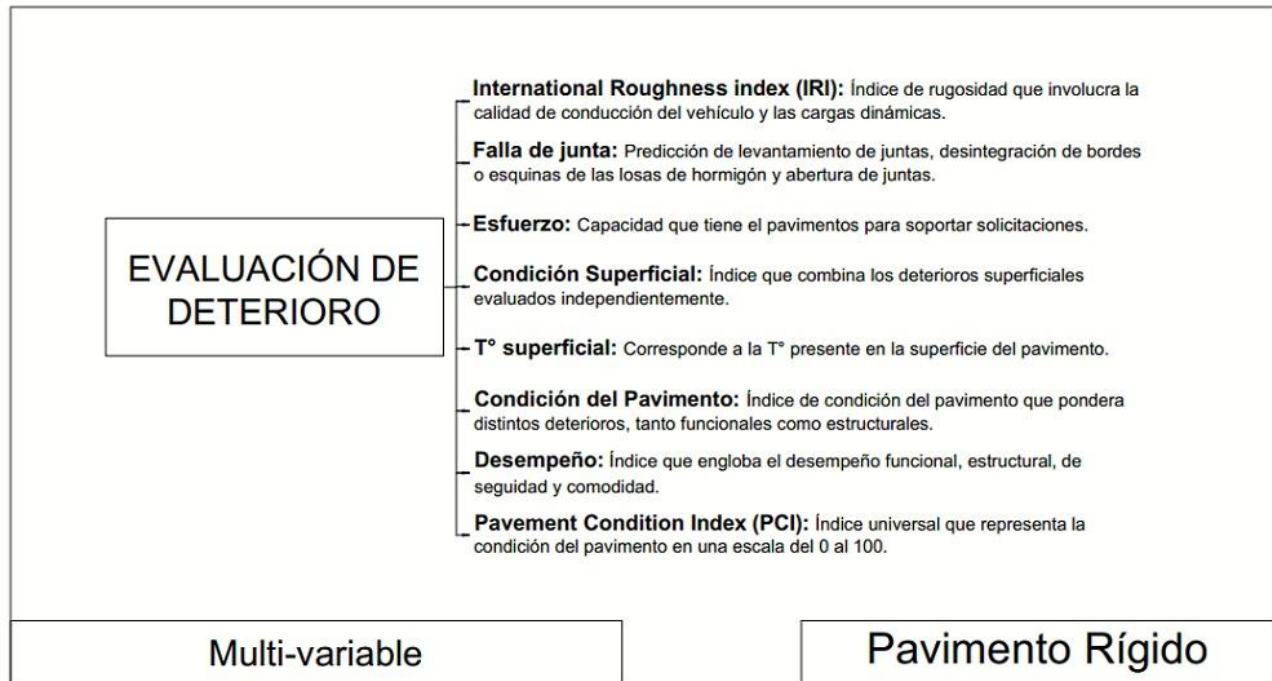


Figura 34: Glosario de variable de predicción para pavimentos rígidos, con enfoque de modelamiento multi-variable.

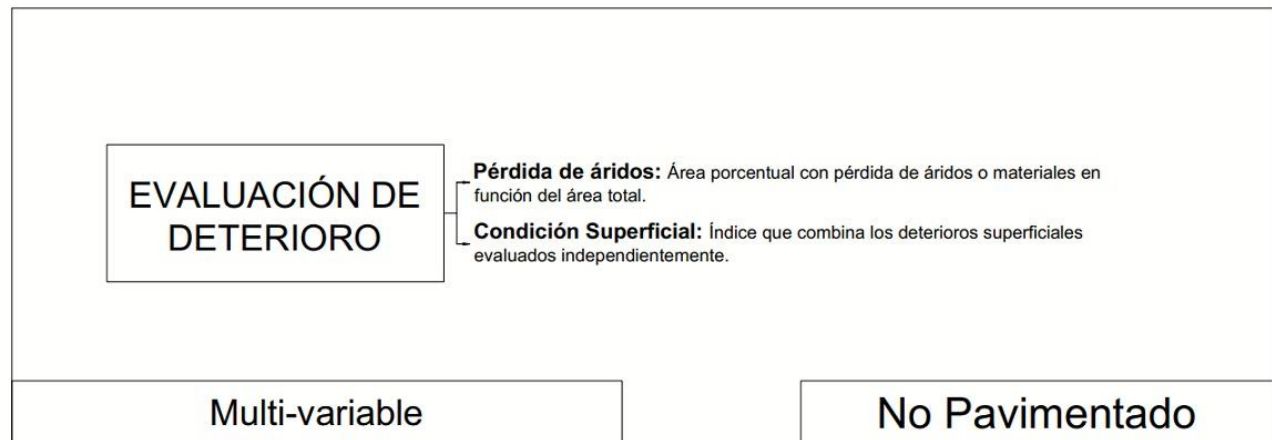


Figura 35: Glosario de variable de predicción para caminos no pavimentados, con enfoque de modelamiento multi-variable.




Figura 36: Glosario de variable de predicción para pavimentos con mejora, con enfoque de modelamiento multi-variable.