


**UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA**

DEPARTAMENTO DE OBRAS CIVILES



METODOLOGÍA Y APLICACIÓN DE ALGORITMOS DE  
MACHINE LEARNING EN EL DESARROLLO DE MODELOS DE  
DESEMPEÑO DE PAVIMENTOS AEROPORTUARIOS EN CHILE

**ANDRÉS IGNACIO MONTECINOS LÓPEZ**

MEMORIA PARA OPTAR AL TÍTULO DE MAGÍSTER EN CIENCIAS DE LA  
INGENIERIA CIVIL

PROFESOR/A GUÍA:

ALELÍ OSORIO LIRD

GABRIEL GARCÍA SAA

OCTUBRE-2021

# Resumen

En el contexto de un convenio de colaboración entre la Universidad Técnica Federico Santa María y la Dirección de Aeropuertos del Ministerio de Obras Públicas, con el fin de fortalecer el sistema de gestión de pavimentos de aeropuerto, fue desarrollada una metodología para desarrollar modelos de desempeño de pavimentos empleando técnicas de Machine Learning (ML).

Los modelos de desempeño juegan un rol clave en cualquier sistema de gestión de infraestructura de pavimentos donde los costos mantención y rehabilitación (M&R) son del orden de millones de dólares. Su principal función es predecir la condición o deterioro experimentado por los pavimentos en el tiempo, así como analizar los efectos de actividades de conservación en el corto o largo plazo.

Una aplicación de la metodología propuesta fue hecha tanto a nivel de proyecto, usando los datos del Aeropuerto Andres Sabella ; como también a nivel de red, con los datos de la red primaria de aeropuertos de Chile. En cada caso se comparó el rendimiento de 4 algoritmos de Machine Learning: Artificial Neural Network (ANN; Redes Neuronales Artificiales), Random Forest Regression (RFR; Regresión de Bosque Aleatorio ), Support Vector Regression (SVR; Regresión de Vectores de Soporte) y Decision Tree Regression (DTR). Por lo demás, diferentes escenarios con distintas variables fueron evaluados, midiendo el efecto de incluir una variable asociada al tránsito (Escenarios 1 a 3) a nivel de proyecto; y por otro lado, evaluando la inclusión de variables asociadas al tránsito y clima a nivel de red (Escenario 4 a 6). Evaluando en un caso aparte (Escenario 7), los efectos de la inclusión de la variable a predecir en un estado anterior.

Entre los resultados de este trabajo, destacan la precisión de los algoritmos de ML, en especial del algoritmo RFR con  $R^2 > 0.9$  en los Escenarios 1 a 6. En tanto, que en el Escenario 7, se mostró que el uso de la variable a predecir en un estado anterior eleva la precisión del modelo de  $R^2 = 0.48$  a  $R^2 = 0.90$ , usando RFR. Adicionalmente, se emplearon regresiones para contrastar resultados a nivel de red, obteniendo una menor capacidad de precisión, no obstante, los resultados no son directamente comparable en términos de variable y de cantidad de datos usados.

**Palabras Claves:** Airport Pavement Management System, Pavement Performance Model, Machine Learning

# Abstract

In the context of a collaboration agreement between Universidad Técnica Federico Santa María and the airports division of the Ministry of Public Works, in order to strengthen the airport pavement management system, a methodology was developed to develop pavement performance models using Machine Learning (ML) techniques.

Performance models play a key role in any pavement infrastructure management system where maintenance and rehabilitation (M&R) costs are in the order of millions of dollars. Their main function is to predict the condition or deterioration experienced by pavements over time, as well as to analyze the effects of maintenance activities in the short or long term.

An application of the proposed methodology was made both at the project level, using data from the Andres Sabella Airport, and at the network level, using data from the primary network of airports in Chile. In each case, the performance of 4 Machine Learning algorithms were compared: Artificial Neural Network (ANN), Random Forest Regression (RFR), Support Vector Regression (SVR) and Decision Tree Regression (DTR). Furthermore, different scenarios with different variables were evaluated, measuring the effect of including a variable associated with traffic (Scenarios 1 to 3) at the project level; and on the other hand, evaluating the inclusion of variables associated with traffic and climate at the network level (Scenario 4 to 6). In a separate case (Scenario 7), the effects of including the variable to be predicted in a previous state were evaluated.

Among the results of this work, the accuracy of the ML algorithms, especially the RFR algorithm with  $R^2 > 0.9$  in Scenarios 1 to 6 stand out. In Scenario 7, it was shown that the use of the variable to be predicted in a previous state increases the accuracy of the model from  $R^2 = 0.48$  to  $R^2 = 0.90$ , using RFR. Additionally, regressions were used to contrast results at the network level, obtaining a lower precision capability, however, the results are not directly comparable in terms of variable and amount of data used.

**keys words:** Aiport Pavement Management System, Pavement Performance Model, Machine Learning

# Agradecimientos

En primer lugar, mis agradecimientos a mi madre por brindarme su amor y apoyo para lograr ser un profesional. En mi mente puedo recordar todo el sacrificio y recorrido que hemos hecho para poder estudiar, por eso mi amor y profundo agradecimiento a quien ha dado su vida por mí.

Además quiero agradecer sinceramente a mi profesora guía, Alelí Osorio Lird; por poner su confianza, apoyo y tiempo en el desarrollo de este trabajo. Por la oportunidad, de poder continuar con mis estudios de Magíster y por haber sido una luz en mi camino.

Quiero reconocer al profesor Gabriel García Saa, por su entrega y compromiso con mi formación y la de muchos de los que fueron mi compañeros. Gracias por la motivación de sus clases, y por despertar en mi el interés por el área de ingeniería vial.

Agradecer a la Dirección de Aeropuertos de Chile, por su disposición y por compartir la base de datos para esta tesis, que sin ella no puede haber realizado. Agradecer especialmente a Edgardo, por el tiempo y consejos recibidos.

Agradecer a Sebastián, Claudio, Maritza y María, por compartir su amistad. A mis compañeros: Felipe M. , Nicolás , Felipe R., Constanza, Macarena, Sebastián y todos aquellos que fueron parte en esta etapa de mi vida. Gracias por el apoyo, consejo y risas que compartimos en todo este tiempo. Agradecimientos a quienes me han entregado su afecto y apoyo y que no he mencionado: familia, por su amor y tantos momentos compartidos ; profesores, por la motivación y experiencias compartidas; a quienes partieron de esta vida, dejando en mí experiencias inolvidables; a mi mascota, que llegó a alegrar mi vida; y también a quien hoy roba mi corazón y pensamientos.

# Tabla de Contenidos

Nomenclatura	xiv
<b>1 Introducción</b>	<b>1</b>
1.1 Planteamiento del Problema . . . . .	3
1.2 Hipótesis . . . . .	4
1.3 Objetivos . . . . .	4
1.3.1 Objetivos Generales . . . . .	4
1.3.2 Objetivos Específicos . . . . .	4
1.4 Metodología . . . . .	5
1.5 Organización de la tesis . . . . .	6
<b>2 Sistemas de Gestión de Pavimentos Aeroportuarios</b>	<b>7</b>
2.1 Sistema de Gestión de Pavimentos Aeroportuarios . . . . .	7
2.1.1 Evaluación de Pavimentos de Aeropuertos . . . . .	9
2.1.2 Necesidades de Mantenimiento y Tratamientos de conservación . . . . .	25
2.2 SGPA en Chile: Estado de la práctica . . . . .	29
2.2.1 Antecedentes . . . . .	30
2.2.2 Avances en la implementación del SGPA Actual . . . . .	31
2.2.3 Desafíos en la implementación del SGPA en Chile . . . . .	38
<b>3 Modelos de Desempeño de pavimentos</b>	<b>39</b>
3.1 Modelos de desempeño de Pavimentos . . . . .	39

3.1.1	Modelo basado en opinión de experto . . . . .	41
3.1.2	Modelo de extrapolación de tendencias . . . . .	42
3.1.3	Modelos de Regresión . . . . .	42
3.1.4	Cadenas de Markov . . . . .	44
3.1.5	Modelos basado en Algoritmos de Machine Learning . . . . .	45
<b>4</b>	<b>Análisis y evaluación de la Base de Datos existente</b>	<b>59</b>
4.1	Antecedes de evaluación de Pavimento Aeroportuarios en Chile . . . . .	59
4.2	Análisis Exploratorio de la Base de Datos . . . . .	63
4.2.1	Análisis Estadístico y Cualitativo de Base de Datos . . . . .	64
4.2.2	Estado de la Red Primaria de Aeropuertos . . . . .	80
4.2.3	Análisis de Predicciones de PCI años anteriores . . . . .	83
<b>5</b>	<b>Propuesta Metodológica para elaboración de Modelos de Desempeño de Pavimentos de Aeropuertos</b>	<b>87</b>
5.1	Metodología Propuesta . . . . .	88
5.1.1	Diagrama Metodológico . . . . .	88
<b>6</b>	<b>Aplicación Metodología para elaborar Modelos de Desempeño usando ML</b>	<b>101</b>
6.1	Aplicación Metodología: Nivel de Proyecto . . . . .	101
6.1.1	Datos de Entrada . . . . .	101
6.1.2	Procesamiento de datos . . . . .	104
6.1.3	Configuración variables y algoritmos . . . . .	108
6.1.4	Entrenamiento y Evaluación de Modelos . . . . .	111
6.2	Aplicación Metodología: Nivel de Red . . . . .	117
6.2.1	Datos de Entrada . . . . .	117
6.2.2	Procesamiento de datos . . . . .	118
6.2.3	Configuración variables y algoritmos . . . . .	123
6.2.4	Entrenamiento y Evaluación de Modelos . . . . .	125

<b>7 Conclusiones, recomendaciones y futuras líneas de investigación</b>	<b>137</b>
7.0.1 Conclusiones de los objetivos de la investigación . . . . .	137
7.0.2 Conclusiones de la investigación . . . . .	138
7.0.3 Recomendaciones Prácticas y futuras líneas de investigación . . . . .	140
<b>A Método PCI</b>	<b>154</b>
<b>B Descripción Base de Datos</b>	<b>156</b>
<b>C Factores Índice de Priorización</b>	<b>162</b>
<b>D Descripción Base de Datos</b>	<b>164</b>
<b>E Base de datos Análisis de Proyecto</b>	<b>168</b>
<b>F Base de datos Modelo a Nivel de Red</b>	<b>171</b>
<b>G Regresiones</b>	<b>182</b>

# Lista de Tablas

2.1	Deterioros típicos de pavimentos de asfalto. . . . .	10
2.2	Deterioros típicos de pavimentos de hormigón. . . . .	13
2.3	Estado de los Pavimentos, según valor de PCI (FAA). . . . .	15
2.4	Niveles de rozamiento. . . . .	24
2.5	Programa de evaluación de rozamiento. . . . .	25
2.6	Tratamientos de conservación típicos según tipo de pavimento. . . . .	26
2.7	Resultados encuesta efectividad y uso tratamientos para pavimentos de asfalto. . . . .	28
2.8	Resultados encuesta efectividad y uso tratamientos para pavimentos de hormigón. . . . .	29
2.9	Estructura de base de datos propuesta por (Alvarez, 2020). . . . .	35
2.10	Matriz de priorización. . . . .	36
3.1	Uso de técnicas para modelar la condición de pavimentos por nivel de gestión. . . . .	41
3.2	Compendio de modelos utilizados para la predicción de PCI en pavimentos de aeropuertos. . . . .	44
3.3	Descripción de algoritmos de ML frecuentemente usados. . . . .	48
3.4	Características de algunos algoritmos de ML. . . . .	50
3.5	Compendio de modelos de desempeño de pavimentos (PCI) usando ML. . . . .	55
4.1	Campañas de evaluación de Pavimentos Método PCI. . . . .	60
4.2	Resumen completo de datos recopilados por área de estudio. . . . .	61
4.3	Frecuencias de mantenimiento e inspecciones. . . . .	62
4.4	Cantidad de datos con información completa según variables consideradas. . . . .	64

4.5	Variables, Tipo, Rangos y/o Categoría de los Datos. . . . .	65
4.6	Estadística Descriptiva variables numéricas. . . . .	66
4.7	Correlación entre PCI y Edad del pavimento por familia de pavimento. . . . .	72
4.8	Operaciones de despegue Red Primaria, período 2000-2019. . . . .	74
4.9	Niveles de operación de despegue, por aeropuerto. . . . .	76
4.10	Clasificación climática de Koppen por aeropuerto. . . . .	79
4.11	Distribución de datos según tránsito, clima y superficie del pavimento. . . . .	80
4.12	Evolución cualitativa sobre el estado del pavimento por aeropuerto. . . . .	83
5.1	Variables Recomendadas para modelar el indicador PCI en aeropuertos usando ML	90
6.1	Descripción de variables y escenarios usados. . . . .	103
6.2	Extracto base de datos Aeropuerto Andrés Sabella. Incluye información sobre condición de pavimento, tipo de pavimento, año de construcción y otros. . . . .	103
6.3	Ejemplo conversión aeronave de diseño equivalente. . . . .	104
6.4	Compendio con valores acumulados de aeronave de diseño equivalente y carga acu- muladas según tipo de eje. . . . .	105
6.5	Descripción de variables numéricas de base de datos filtrada. . . . .	107
6.6	Descripción de variables numéricas,para conjunto de entrenamiento-validación y prueba . . . . .	107
6.7	Ejemplo de binarización y escalamiento de variables de entrada (Escenario 1) . . . .	108
6.8	Importancia de variables por escenario de estudio. . . . .	110
6.9	Resultados del ajuste de hiperparámetros con Grid Search de Scikit Learn. . . . .	111
6.10	Evaluación cuantitativa de resultados en etapa entrenamiento-validación, según Es- cenarios 1, 2 y 3. . . . .	112
6.11	Resultados etapa de prueba Escenarios 1, 2 y 3. . . . .	112
6.12	Resultados test de hipótesis. . . . .	113
6.13	Tiempo de ajuste de algoritmos por escenarios (en segundos). . . . .	115
6.14	Análisis de errores de los modelos de la literatura y del modelo propuesto. . . . .	117
6.15	Descripción de variables y escenarios usados (Nivel de Red). . . . .	118

6.16	Ejemplo limpieza de datos, eliminando datos que experimenten incremento en la condición de PCI. . . . .	119
6.17	Extracto base de datos, para análisis a nivel de red. . . . .	122
6.18	Ejemplo escalamiento de variables y transformación datos cualitativos para Escenario 4. . . . .	122
6.19	Descripción de datos cuantitativos para conjunto de entrenamiento y prueba. . . . .	122
6.20	Nivel de importancia de variables análisis nivel de red. . . . .	124
6.21	Niveles de Importancia de variables según Escenario en estudio. . . . .	124
6.22	Evaluación cuantitativa de resultados en etapa entrenamiento-validación, según Escenarios 4, 5, 6 y 7. . . . .	125
6.23	Resultados etapa de prueba, para modelos de desempeño de pavimentos a nivel de red. . . . .	126
6.24	Resultados test de hipótesis, a nivel de red. . . . .	127
6.25	Tiempo de ajuste de algoritmos en escenario 4 a 8. . . . .	129
6.26	Compendio regresiones por familia de pavimento. . . . .	135
B.1	Estructura Base de datos propuesta Alvarez (2020). . . . .	157
C.1	Factor de Operaciones. . . . .	162
C.2	Factor Rama. . . . .	163
C.3	Factor Secciones Características. . . . .	163
D.1	Compendio resumen, con rangos de valores típicos de base de datos. . . . .	164
E.1	Datos empleados para modelo de desempeño de pavimento a nivel de proyecto. . . . .	168
F.1	Base de datos empleada para modelo de desempeño a nivel de red. . . . .	171

# Lista de Figuras

1.1	Esquema resumen sobre metodología de investigación propuesta. . . . .	5
2.1	Planilla de Registro de deterioros, método PCI. . . . .	17
2.2	Curvas de deducción para deterioro piel de cocodrilo. . . . .	18
2.3	Clasificación de estado de los pavimentos, de acuerdo al BBI. . . . .	20
2.4	Escala estándar IRI del Banco Mundial. . . . .	22
2.5	Procedimiento medición de irregularidades. . . . .	23
2.6	Red de Aeropuertos y pequeños Aeródromos de Chile. . . . .	31
2.7	Marco Teórico para la Gestión de Pavimentos Aeroportuarios en Chile. . . . .	34
3.1	Ciclo de vida típico de la condición del pavimento. . . . .	40
3.2	Ejemplo Extrapolación Lineal. . . . .	42
3.3	Ejemplo Regresión Lineal . . . . .	43
3.4	Ejemplo MTP . . . . .	45
3.5	Red de Aeropuertos y pequeños Aeródromos de Chile. . . . .	47
3.6	Componentes a considerar en Modelos de Desempeño de Pavimentos. . . . .	50
3.7	Ejemplo ilustrativo sobre overfitting y underfitting. . . . .	52
3.8	Distribución de estudios de ML en modelos de desempeño de pavimento por intervalo de año. . . . .	53
3.9	Ejemplo de resultado de Herramienta de visualización de aplicaciones de ML en modelos de desempeño de pavimentos. . . . .	54
3.10	Herramientas de ML para cada variable de predicción, según tipo de pavimento. . .	55

4.1	Distribución de variables cualitativas. . . . .	67
4.2	Distribución de variables numéricas. . . . .	68
4.3	Matriz de correlación lineal (Pearson) entre variables numéricas. . . . .	69
4.4	Análisis de dispersión de la base de datos en función del indicador PCI y la edad del pavimento. . . . .	70
4.5	Distribución de PCI por rama y tipo de superficie. . . . .	71
4.6	Distribución lateral del tránsito. . . . .	73
4.7	Operaciones anuales de despegue en aeropuertos de Red Primaria. . . . .	74
4.8	Dendrograma que agrupa aeropuertos según operaciones de despegue. . . . .	75
4.9	Evolución media de los índices de silhouette. . . . .	76
4.10	Clasificación climática del territorio nacional, según Koppen. . . . .	77
4.11	Simbología clasificación climática de Koppen. . . . .	78
4.12	Estado Red Primaria de aeropuerto en base a indicador PCI. . . . .	81
4.13	Escala de clasificación del estado del pavimento en PCI. . . . .	82
4.14	Correlación existente entre valores medidos y predichos de PCI. . . . .	84
4.15	Análisis de residuos para predicciones de PCI. . . . .	85
4.16	Distribución de Error Absoluto por rama. . . . .	86
5.1	Componentes a considerar en Modelos de Desempeño de Pavimentos. . . . .	88
5.2	Esquema general propuesto para elaborar modelos de desempeño de pavimentos de aeropuertos con ML. . . . .	89
5.3	Esquema de procesos para Etapa 1. . . . .	90
5.4	Esquema de procesos para Etapa 2. . . . .	91
5.5	Esquema de procesos para Etapa 3. . . . .	95
5.6	Esquema de procesos para Etapa 4. . . . .	97
5.7	Componentes a considerar en Modelos de Desempeño de Pavimentos. . . . .	98
5.8	Esquema de procesos para Etapa 5. . . . .	100
6.1	Distribución de PCI por tipo de pavimento y rama. . . . .	106

6.2	Resultados RFECV por escenario. . . . .	109
6.3	Análisis cualitativo de resultados Escenario 3-RFR. . . . .	114
6.4	Comparación de predicciones para secciones PI-1 Y RA-1, aeropuerto Andrés Sabella. . . . .	115
6.5	Comparación resultados modelos de la literatura y propia, secciones de referencia PI-1 y RA-1 de aeropuerto Andrés Sabella. . . . .	116
6.6	Distribución de datos según zona climática. . . . .	120
6.7	Distribución de datos según nivel de operaciones, según Tabla4.9. . . . .	120
6.8	Distribución de datos según tipo de superficie de pavimento. . . . .	121
6.9	Distribución de datos según tipo de pavimento (convencional, recapado, mixta o mixta. . . . .	121
6.10	Elección de características según RFECV, nivel de red. . . . .	123
6.11	Análisis cualitativo de resultados Escenario 4 usando RFR, para análisis nivel de red. . . . .	128
6.12	Comparación resultados medidos y predichos para secciones PI-3 y DD-1, aeropuerto Andrés Sabella. . . . .	129
6.13	Proyecciones PCI 2020-2025 para aeropuerto Andrés Sabella, usando RFR y variables Escenario 4. . . . .	130
6.14	Proyecciones PCI 2020-2030 para aeropuerto La Florida, usando RFR y variables Escenario 4. . . . .	131
6.15	Proyecciones PCI 2020-2025 para aeropuerto Desierto de Aacama, usando RFR y variables Escenario 4. . . . .	131
6.16	Proyecciones PCI 2020-2030 para aeropuerto Balmaceda, usando RFR y variables Escenario 4. . . . .	132
6.17	Proyecciones PCI 2020-2030 para aeropuerto La Araucanía, usando RFR y variables Escenario 4. . . . .	132
6.18	Proyecciones PCI 2020-2030 para aeropuerto Presidente Carlos Ibáñez del Campo, usando RFR y variables Escenario 4. . . . .	133
6.19	Ejemplo análisis de sensibilidad en base a grado de polinomio. . . . .	134
6.20	Análisis de regresión con polinomio de grado 1 a 3. . . . .	134
6.21	Regresiones señaladas en tabla 6.26. . . . .	135

G.1 Diagnóstico Residuos para Pista-Templado-Lluvias todo el año-Bajo . . . . .	182
G.2 Diagnóstico Residuos para Plataforma-Seco-Árido . . . . .	183
G.3 Diagnóstico Residuos para Pista-Bajo . . . . .	184

# Nomenclatura

*ANN*= Artificial Neural Network

*ASTM*= American Society for Testing and Materials

*DAN*= Las Norma de Aeronáuticas

*DAP*= Dirección de Aeropuertos de Chile

*DGAC*= Dirección de Aeronáutica Civil

*DTR*= Decision Tree Regression

*FAA*= Federal Aviation Administration

*ML*= Machine Learning

*PCI*= Pavement Condition Index

*RFR*= Random Forest Regression

*SGP*= Sistema de Gestión de Pavimentos

*SGPA*= Sistema de Gestión de Pavimentos Aeroportuarios

*SVR*= Support Vector Regression

# Capítulo 1

## Introducción

El transporte aéreo constituye un factor importante para el desarrollo y crecimiento económico; permitiendo la integración económica y la conectividad a escala nacional, regional e internacional (The World Bank, 2020). De ahí los esfuerzos de cientos de gobiernos por promover la ampliación de sus redes y al mismo tiempo la preocupación por mantener las redes existentes en buen estado, asegurando la calidad, seguridad y competitividad.

Parte importante de la infraestructura aeroportuaria son los pavimentos, los cuales proporcionan una superficie para que las aeronaves realicen las maniobras de aterrizaje y despegue, de forma segura. Requiriendo de actividades de mantenimiento oportunas para evitar que estos se deterioren en demasía producto de múltiples factores como el clima, la frecuencia y tipo de carga, entre otros.

Los sistemas de gestión de pavimentos aeroportuarios (SGPA) cumplen un rol clave en esta tarea, ayudando a las agencias a cargo de la administración de los pavimentos a tomar decisiones en base a estrategias económicamente viables para mantener los pavimentos en condiciones de servicio bajo un determinado estándar; proporcionando procedimientos sistemáticos para determinar prioridades para la asignación de recursos y cuantificar la información (Tighe and Covalt, 2008).

Un estudio realizado sobre el estado de los SGPA en los Estados Unidos (Covalt et al., 2019), indica que el 82% de los estados posee un SGPA activo, un 12% tuvieron en algún momento y solo el 6% no han tenido nunca. En cambio en Chile, la implementación de un SGPA se encuentra en desarrollo a cargo de la Dirección de Aeropuertos del Ministerio de Obras Públicas, institución encargada de la administración de los servicios de infraestructura aeroportuaria.

Por otro lado, en los últimos años el uso de técnicas de ML en la ingeniería civil y en particular la ingeniería de pavimentos ha ido en aumento (Ceylan et al., 2014). Algunas aplicaciones de ella en este campo es: la determinación de módulo de elástico para carpetas asfálticas (Bayrak and Ceylan, 2008; Gopalakrishnan and Papadopoulos, 2011; Khazanovich and Roesler, 1997); la

asignación de estrategias de mantenimiento (Abdelrahim and George, 2000; Huang et al., 2005); la detección automática de los espesores de pavimento (Sukhobok et al., 2019); detección automática de deterioros en pavimentos y/o indicadores de condición (Huincaléf et al., 2018; Zhang et al., 2017a; Yan and Zhang, 2011; Shahnazari et al., 2012; Roberts and Attoh-Okine, 1998; Lin et al., 2003); entre otros.

ML en palabras simples, es una rama de la inteligencia artificial capaz de resolver problemas de alta complejidad sin ser programados explícitamente mediante reglas como lo es la programación clásica (Rebala et al., 2019). Uno de los pioneros de ML es Arthur Samuel (1960) 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 de las redes neuronales actuales. A pesar de estos avances, no fue hasta mediados del año 2000 que comenzó otro apogeo, debido en gran parte por (Rebala et al., 2019) : la gran cantidad de datos debido a internet; la potencia de cómputo, respaldada por una buena capacidad de memoria y almacenamiento; algoritmos mejorados que fueron optimizados para trabajar con gran conjunto de datos.

Con el tiempo ha surgido una sub área denominada Deep Learning que emplea redes neuronales con una alta cantidad de capas o niveles jerárquicos que son capaces de aprender mejor que modelos más superficiales o con menor cantidad de capas. Estas técnicas sin lugar a dudas han generado innumerables avances entre los que se destacan la capacidad de resolución de problemas casi al nivel humano como (Chollet, 2017): 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.

Este trabajo aborda el desarrollo de una metodología para elaborar modelos de desempeño de pavimentos para el SGPA chilenos; poniendo énfasis en el uso de algoritmos de ML que en pavimentos de carreteras han demostrado buenos resultados (Alharbi, 2018; Yao et al., 2019; Tabatabaee et al., 2013; Gong et al., 2018; Marcelino et al., 2021)

Asimismo esta metodología propuesta, será aplicada a un caso de estudio en el Aeropuerto Andrés Sabella, Chile; analizando 3 escenarios de estudios basados en la consideración de la variable asociada al tránsito aéreo más la inclusión de otras variables asociadas al tipo de pavimento, uso, espesores, edad del firme, entre otros. Asimismo, se hará un análisis a nivel de red, con datos facilitados por la Dirección de Aeropuertos de la red primaria de aeropuertos de Chile.

## 1.1 Planteamiento del Problema

Este trabajo se enmarca dentro de un convenio de colaboración entre la Universidad Técnica Federico Santa María y la Dirección de Aeropuertos (DAP) del Ministerio de Obras Públicas, que por medio de la investigación busca potenciar el desarrollo y ejecución de proyectos para pavimentos aeroportuarios y la el fortalecimiento del sistema de gestión de pavimentos aeroportuarios.

En este contexto y considerando además los desafíos de la DAP por proveer la infraestructura aeroportuaria adecuada ante las alzas en la demanda, la incorporación de nuevas rutas y aeronaves; es necesario fortalecer el actual sistema de gestión de pavimentos elaborando diferentes herramientas y procedimientos para su funcionamiento.

Este trabajo, se hace cargo de desarrollar una propuesta metodológica para elaborar modelos de desempeño de pavimentos aeroportuarios empleando técnicas de ML; junto con algunas recomendaciones de recolección y administración de las bases de datos para su construcción. Por su parte, La relevancia de esta investigación radica en:

- Que es una herramienta no desarrollada en la actualidad por la DAP y su desarrollo ayudará a la toma de decisiones de gestores de infraestructura, encargados de la conservación y mantenimiento de los pavimentos de aeropuertos del país.
- Que su implementación permitirá tomar decisiones de intervención de manera oportuna, evitando la pérdida de valor del patrimonio y el deterioro excesivo de los pavimentos que pueden afectar a la normal operación de los aeropuertos.
- Que se podrá integrar con el SGPA actual de la DAP, permitiendo realizar una correcta distribución de los recursos destinados año a año, empleando una priorización basada bajo un indicador objetivo como lo es el indicador de condición de pavimentos PCI.
- Por el lado científico, el aporte de esta investigación es aplicar técnicas de ML en pavimentos aeroportuarios, sirviendo de precedente para los sistemas de gestión de aeropuertos de la región.
- Que contar con la aplicación de una metodología innovadora para el desarrollo de los modelos, podría servir para aplicar a otros tipos de indicadores de pavimentos de aeropuertos como también a otros tipos de infraestructuras.

## 1.2 Hipótesis

El desarrollo de una metodología para elaborar modelos de desempeño de pavimentos de aeropuertos basados en ML; pueden ayudar a obtener modelos de desempeño más eficientemente, en términos de precisión. Capturando el deterioro del pavimento producto de los efectos del tránsito, clima, tipo de estructura y uso.

## 1.3 Objetivos

### 1.3.1 Objetivos Generales

Desarrollar una metodología para la elaboración de modelos de desempeño de pavimentos de aeropuertos chilenos usando técnicas de ML. Validando su uso con una aplicación nivel de proyecto, basado en los datos del aeropuerto Andrés Sabella; y una aplicación a nivel de Red con datos de la Red Primaria de aeropuertos de Chile.

### 1.3.2 Objetivos Específicos

En relación a los objetivos específicos, estos se identifican como:

1. Comprender el uso de técnicas de ML en el desarrollo de modelos de desempeño en la literatura. Identificando las principales variables usadas, algoritmos, resultados, ventajas y desventajas de los métodos usados.
2. Recopilar información relacionada con el deterioro del pavimento como: indicadores funcionales y estructurales del pavimento, datos del tránsito, ubicación, uso, entre otros. Analizando la factibilidad de usar cada una de estas variables en base a la cantidad y calidad de la información recopilada.
3. Definir una metodología para la elaboración de modelos de desempeño de pavimentos aeroportuarios usando ML: indicando variables de entrada recomendadas, tratamiento de los datos, aplicación de los algoritmos y metodología de evaluación de ellos.
4. Aplicar y Evaluar la metodología propuesta con la base de datos del Aeropuerto Andrés Sabella y los disponible de la red primaria de aeropuertos. Comparando rendimientos de los modelos de acuerdo a métricas de evaluación, tiempos de entrenamiento y complejidad.

## 1.4 Metodología

En función de lograr los objetivos propuestos, a continuación, se presenta el procedimiento y aspectos a abordar para el desarrollo de la investigación (ver Figura 1.1):

- Revisión bibliográfica asociada al tema en análisis: Búsqueda de material y análisis del estado del arte y de la práctica relacionada con modelos de desempeños en el ámbito vial y de aeropuertos.
- Revisión de antecedentes y base de datos: Estudio de información disponible acerca del estado de los pavimentos de aeropuertos a nivel nacional. Incluye revisión de informes de evaluación estructural y funcional de los pavimentos, además de estudios de tránsito aéreo.
- Diagnóstico de la información recolectada y procesamiento de datos: Reconocimiento de falencias en el proceso de toma de datos e identificación de los elementos no incluidos en dicho proceso, y que resultan necesarios para la elaboración de un modelo de desempeño.
- Planteamiento de metodología para elaborar modelos de desempeño usando ML: Formulación del marco teórico para la elaboración de modelos de desempeño de pavimentos de aeropuertos usando técnicas de ML. Incluye procesamiento de datos, técnicas de optimización de variables e hiperparámetros, etapas de entrenamiento, validación y prueba.
- Validación metodología con aplicación de algoritmos de ML, evaluación y análisis de resultados.

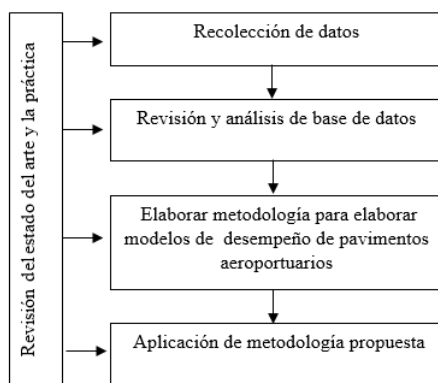


Figura 1.1: Esquema resumen sobre metodología de investigación propuesta.

Fuente: Elaboración Propia.

## 1.5 Organización de la tesis

Esta tesis se encuentra organizada en base a los siguientes capítulos:

- **Introducción:** Este capítulo introduce a la importancia de la Infraestructura aeroportuaria y el uso de herramientas ML para resolver problemas de gestión de pavimentos. A continuación, se plantea el problema a resolver y su importancia, la hipótesis, los objetivos y la metodología de investigación.
- **Sistemas de gestión de pavimentos aeroportuarios:** Incluye una revisión detallada sobre los sistemas de gestión de pavimentos aeroportuarios incluyendo la evaluación de pavimentos, necesidades de mantenimiento y una revisión sobre el estado de la práctica en la gestión de pavimentos aeroportuarios en Chile.
- **Modelos de desempeño de pavimentos:** Hace una revisión detallada sobre las herramientas usadas en la literatura para modelar el desempeño de los pavimentos. Revisando especialmente el uso de técnicas de ML para esta tarea.
- **Análisis y evaluación de la base de datos existente:** Análisis de la información disponible en la base de datos de la DAP. Indica frecuencia de muestreo de datos, indicadores medidos y cantidad de datos disponible. Adicionalmente, se analiza el estado de la red primaria en términos del indicador PCI y el nivel de precisión existente en las proyecciones de PCI hechas con anterioridad.
- **Propuesta metodológica para elaborar modelos de desempeño de pavimentos aeroportuarios con ML:** En este capítulo se formula una serie de etapas para elaborar, optimizar y evaluar modelos de desempeño de pavimentos aeroportuarios usando algoritmos de ML.
- **Conclusiones y recomendaciones:** Conclusiones de la investigación, recomendaciones para aplicación y uso de la herramientas desarrolladas, las contribuciones de la tesis y las investigaciones y desarrollos futuros se presentan en este capítulo.

# Capítulo 2

## Sistemas de Gestión de Pavimentos Aeroportuarios

En este capítulo se presenta un marco teórico acerca de los sistemas de gestión de pavimentos de aeropuertos y sus componentes.

Incluyendo además, una revisión profunda acerca de la evaluación técnica de los pavimentos y el estado de la práctica de la implementación de un SGPA en Chile.

### 2.1 Sistema de Gestión de Pavimentos Aeroportuarios

En términos generales, un sistema de gestión de pavimentos (SGP) se define como un conjunto de herramientas que trabajan de forma coordinada para ayudar a los administradores de los pavimentos a la toma de decisiones; integrando en un único sistema el diagnóstico, evaluación, planificación y ejecución de las actividades (Solminihac et al., 2018).

La Federal Aviation Administration (FAA), define en la Circular AC 150/5380-7B que, los SGPA son los procedimientos para recolectar, analizar, mantener e informar datos sobre los pavimentos. Ayudando a determinar la estrategia óptima de mantenimiento al menor costo posible, asegurando cierto estándar durante determinado período de tiempo.

De acuerdo con Solminihac et al. (2018), los SGP son esencialmente necesarios cuando la complejidad y el tamaño de la red de pavimentos es tan grande, que urge contar con una herramienta de priorización y asignación de recursos de manera óptima, con tal de actuar de manera preventiva y no caer en sobrecostos de mantenimiento tardío. Además, se requieren cuando sea necesario mejorar la eficiencia económica, que se traduce en maximizar el beneficio social, la competitividad

del transporte y la cadena logística que de ella deriva.

Los beneficios de contar con un sistema de gestión de pavimentos son variados (Solminihac et al., 2018; Di Mascio and Moretti, 2019): permiten mantener los pavimentos en un estándar adecuado, evitando que los pavimentos lleguen a niveles de deterioro no deseados, aumentando su vida útil; permiten planificar la asignación presupuestaria, definiendo el cómo, cuándo y dónde intervenir, optimizando recursos a partir de un análisis de costo y beneficios asociados a las alternativas de mantenimiento y/o reconstrucción; procuran generar y mantener una base de datos acerca del estado de los pavimentos y las actividades de M&R, que luego se traduce en una retroalimentación de las actividades hechas, junto con creación de modelos que caractericen el desempeño de los pavimentos para la toma de decisiones futuras con una mayor precisión .

Asimismo, en la literatura se ha evidenciado el beneficio que genera la implementación los SGP expresado en términos de: la mejora en la condición del pavimento (Falls et al., 1994; Sztraka and Eng, 2001; Smadi, 2004; Mizusawa and McNeil, 2005), ahorro costos de usuarios (Falls et al., 1994; Cohen, 2018), análisis costo-beneficio (Mizusawa and McNeil, 2009; Haas and Hudson, 2015), entre otros.

Por otro lado, para que un SGP cumpla sus objetivos se requiere contar con los siguientes componentes (Tighe, 2013; AC150/5380-7B, 2014):

- Una base de datos que sea capaz de almacenar y mantener actualizado múltiples datos como: el inventario del pavimento, la composición estructural del pavimento, el estado del pavimento, datos del tránsito e información de sobrecosto. En este contexto, resulta relevante para las instituciones a cargo de la gestión de pavimentos conocer los costos asociados a las actividades de mantenimiento para cuantificar el costo de la mejora de la condición del pavimento. Además de identificar el lugar, fecha y tipo de acciones de M&R realizadas en los pavimentos. Este componente es de vital importancia para la toma de decisiones.
- Normas y protocolos para la evaluación de los pavimentos y frecuencia de muestreo de ellos. Debe definirse que indicadores (funcionales y/o estructurales) medir.
- Asimismo, deben definirse las estrategias, políticas y umbrales de mantenimiento o rehabilitación. Que sirven para identificar las alternativas de mantención y/o rehabilitación dado cierto escenario y los estándares a cumplir del pavimento en base mínimos o máximos de determinada condición del pavimento.
- Herramientas de análisis de la información, capaz de predecir el estado de los pavimentos en un futuro, priorizar y optimizar los costos y beneficios de la institución en base a la selección de la mejor actividad de M&R a largo plazo.

El desarrollo de cada componente dependerá de cada institución, incluyéndose si se desea algunos atributos medioambientales y sostenibles para la toma de decisiones (Machí, 2015).

Por lo demás, el nivel de información requerido para la toma de decisiones dependerá de si hace un análisis de red o a nivel de proyecto (Haas et al., 1994; Di Mascio and Moretti, 2019). El análisis de red, se encarga de hacer un análisis a corto y largo plazo de las necesidades presupuestarias y de priorización de todas las secciones de una red. Mientras que el análisis a nivel de proyecto, responde a la necesidad de otorgar la mejor estrategia de mantenimiento, para ello se requiere un estudio detallado, incluyendo si fuese necesario ensayos no destructivos y/o destructivos, mediciones de rugosidad u otros.

### **2.1.1 Evaluación de Pavimentos de Aeropuertos**

Conocer el estado de los pavimentos es clave para la toma de decisiones en un SGP. Al mismo tiempo, sin datos precisos los resultados del SGP serían poco fiables (Gendreau and Soriano, 1998). Por ello, cada SGP debe definir los deterioros o indicadores de pavimentos de aeropuertos a evaluar, en base a los estándares de seguridad y operación que se pretenden lograr, junto con la disponibilidad de recursos en términos de equipo y personal capacitado para esta tarea.

En esta sección se hace una revisión acerca de los deterioros presentes en pavimentos de aeropuertos, junto con los indicadores estructurales y/o funcionales usados para evaluar el estado de los pavimentos en aeropuertos.

#### **Deterioros en pavimentos de Aeropuertos**

La norma de ASTM D 5340, empleada para determinar el PCI, define una serie de deterioros de pavimentos aeropuertos que son usados en este trabajo para describir los deterioros tanto de pavimentos rígidos y flexibles. Asimismo la DAP, cuenta con un manual de deterioros característico del método PCI y que se resumen en la Tabla 2.1 para deterioros de pavimentos asfálticos y en la Tabla 2.2 para pavimentos de hormigón.

Tabla 2.1: Deterioros típicos de pavimentos de asfalto.

Deterioro/ Unidad Medida	Descripción	Opciones de Reparación Según grado de severidad
Piel de cocodrilo [m <sup>2</sup> ]	Se presentan como un conjunto de grietas interconectadas, causadas por fatiga de la carpeta asfáltica sometida a repetidas cargas de tránsito.	B:No reparar; Recapar M:Parchar a profundidad parcial o total; Recapar; Reconstruir A:Parchar a profundidad parcial o total; Recapar; Reconstruir
Exudación [m <sup>2</sup> ]	Se presenta como una película de material bituminoso, sobre la superficie del pavimento. Se asemeja a una capa vidriosa y brillante, que generalmente es bastante pegajosa.	No reparar; Aplicar calor, esparcir arena y retirar el material suelto.
Fisura de bloque [m <sup>2</sup> ]	Son grietas interconectadas que dividen el pavimento en bloques aproximadamente rectangulares.	B :No reparar. M: Sellar grietas; Reciclar la superficie; Escarificar en caliente y recapar. A:Sellar grietas; Reciclar la superficie; Escarificar en caliente y recapar.
Corrugamiento [m <sup>2</sup> ]	Es un ondulamiento de la superficie. Se presentan una serie de crestas y valles, en intervalos regulares normalmente menores que 1,50 m, a lo largo del pavimento.	B:No reparar. M:Reconstruir. A:Reconstruir.
Depresiones [m <sup>2</sup> ]	Son áreas localizadas en la superficie del pavimento, cuyo nivel es ligeramente menor que el del pavimento adyacente. En muchos casos, las pequeñas depresiones son perceptibles sólo después de una lluvia.	B:No reparar. M:Parchar parcial y superficialmente (*) o parchar completamente y en toda su profundidad. A:Parchar parcial y superficialmente (*) o parchar completamente y en toda su profundidad.
Erosión por chorro de jet [m <sup>2</sup> ]	Se distingue por la presencia de áreas oscurecidas en la superficie del pavimento, donde el ligante asfáltico ha sido quemado o carbonizado.	No reparar; Aplicar parche de profundidad parcial

**Table 2.1 Deterioros típicos de pavimentos de asfalto (Continuación).**

Deterioro/ Unidad Medida	Descripción	Opciones de Reparación Según grado de severidad
Grietas de reflexión de juntas de pavimentos de hormigón [m]	Este deterioro se presenta sólo en pavimentos asfálticos construidos sobre un pavimento de hormigón hidráulico. Se origina principalmente por movimientos de las losas de hormigón bajo el concreto asfáltico, causados por los cambios térmicos y de humedad.	B:No reparar; Sellar grietas de espesor mayor que 3 mm. M:Sellar grietas; Parchar a profundidad parcial. A:Sellar grietas; Parchar a profundidad; Reconstruir.
Grietas longitudinales y transversales. [m]	Las grietas longitudinales son paralelas al eje del pavimento. Las grietas transversales se extienden a través del pavimento, en dirección aproximadamente perpendicular al eje de este.	B:No reparar; Sellar las grietas de espesor mayor que 3 mm. M:Sellar grietas. A:Sellar grietas; Parchar a profundidad parcial.
Derrame de aceites solventes [m <sup>2</sup> ]	Es el deterioro o reblandecimiento de la superficie del pavimento, causado por el derrame de combustibles, aceites u otro solvente.	No reparar; Parchar a profundidad parcial o total.
Bacheos [m <sup>2</sup> ]	Son sectores en los cuales se ha reemplazado la carpeta existente por otro material. Un bacheo es considerado un defecto, independiente de lo bien que se esté comportando.	B:No reparar. M:Sellar grietas; Reparar deterioros en los parches; Reemplazar el parche. A:Reemplazar el parche.
Agregados pulidos [m <sup>2</sup> ]	El pulido de los agregados es causado por repetidas aplicaciones de tránsito.	No reparar; Recapar; Ranurar.
Erosión superficial [m <sup>2</sup> ]	Es el desgaste del pavimento causado por el desprendimiento de partículas de agregado y pérdida de asfalto.	B:No reparar. M:No reparar. A:Recapar; Reciclar; Reconstruir.

**Table 2.1 Deterioros típicos de pavimentos de asfalto (Continuación).**

Deterioro/ Unidad Medida	Descripción	Opciones de Reparación Según grado de severidad
Ahuellamiento [m <sup>2</sup> ]	Es una depresión del pavimento en la trayectoria de la rueda.	B:No reparar. M:Parchar superficialmente (*), a profundidad parcial o total; Parchar a profundidad parcial o total; Recapar. A:Parchar superficialmente (*), a profundidad parcial o total; Parchar a profundidad parcial o total; Recapar.
Levantamiento en unión de pavimentos asfálticos por empuje de pavimento de hormigón [m <sup>2</sup> ]	Los pavimentos de hormigón, ocasionalmente, "aumentan" su longitud en la unión con los pavimentos flexibles.	B:No reparar. M:Parchar a profundidad parcial; Parchar a profundidad total. A:Parchar a profundidad parcial; Parchar a profundidad total.
Grietas por resbalamiento [m <sup>2</sup> ]	Tienen la forma de media luna, con sus extremos orientados hacia fuera y en contra de la dirección del tráfico. Se producen cuando el frenado o giro de las ruedas, desliza y deforma el pavimento asfáltico.	No reparar; Parchar a profundidad parcial o total.
Hinchamiento [m <sup>2</sup> ]	Se caracteriza por presentar un levantamiento de la superficie del pavimento. Puede ocurrir puntualmente sobre una pequeña superficie, o como una onda gradual más larga.	B:No reparar. M:Reconstruir. A:Reconstruir.

Fuente: DAP (2002). Manual de deterioros característicos en Asfalto.

Nota: según el grado de severidad considere, B=Baja; M=Media y A=Alta.

Tabla 2.2: Deterioros típicos de pavimentos de hormigón.

Deterioro/ Unidad Medida	Descripción	Opciones de Reparación Según grado de severidad
Levantamiento de losas por dilatación (blow up) [Losas]	Se produce, en tiempo caluroso, usualmente en una grieta transversal o en una junta que no es lo suficiente- mente ancha como para permitir la expansión del hormigón, produciendo un movimiento ascendente de los bordes de la losa, con daño en la cercanía de la junta.	B: Parchar a profundidad parcial o total; Reemplazar la(s) losa(s). M: Parchar a profundidad parcial o total; Reemplazar la(s) losa(s). A: Parchar a profundidad total; Reemplazar la(s) losa(s).
Grietas de esquina [Losas]	Es una grieta que intercepta los bordes encontrados de una losa, a una distancia menor o igual a la mitad de la longitud de cada borde, medidos desde la esquina de la losa.	B: No reparar; Sellar grietas. M: Sellar grietas; Parchar a profun- didad total; Reemplazar la losa. A: Sellar grietas; Parchar a profun- didad total; Reemplazar la losa.
Grietas longitudinales, transversales y diagonales [Losas]	Estas grietas dividen las losas en dos o tres sectores. Normalmente son causa- das por interacción de cargas repetidas, tensiones de alabeo y tensiones de fraguado.	B: No reparar; Sellar grietas. M: Sellar grietas. A: Sellar grietas; Parchar a profun- didad total; Reemplazar la losa.
Grietas tipo "D" [Losas]	Son causadas por la incapacidad del hormigón para soportar factores ambien- tales, como ciclos hielo - deshielo. Generalmente se presentan como una configuración de grietas paralelas a la juntura de la losa o a una grieta lineal y se acompañan de una coloración oscura a su alrededor.	B: No reparar. M: Parchar a profundidad total; Reconstruir las juntas. A: Parchar a profundidad total; Reconstruir las juntas; Reem- plazar la losa.
Daño al sello de juntas	Se define como cualquier condición capaz de permitir que partículas de suelo o piedras se acumulen en las juntas, o que permita una infiltración significativa de agua.	B: No reparar. M: Sellar juntas. A: Sellar juntas.
Parches menores o iguales que 0.5 m <sup>2</sup> [Losas]	Un parche es un área donde el pavimento original ha sido removido y reemplazado por un material de relleno.	B: No reparar. M: Reemplazar el parche. A: Reemplazar el parche.

**Table 2.2 Deterioros típicos de pavimentos de hormigón (Continuación).**

Deterioro/ Unidad Medida	Descripción	Opciones de Reparación Según grado de severidad
Parches mayores a 0.5 m <sup>2</sup> [Losas]	Son pequeñas partes del pavimento que se desprenden de la superficie del pavimento, debido al efecto hielo-deshielo en combinación con agregados expansivos.	B:No reparar. M:Sellar grietas; Reparar el área deteriorada; A:Reemplazar el parche. Reemplazar la losa.
Agujeros [Losas]	Son pequeñas partes del pavimento que se desprenden de la superficie del pavimento, debido al efecto hielo-deshielo en combinación con agregados expansivos.	No reparar
Bombeo [Losas]	El bombeo es la expulsión de material arrastrado por el agua, a través de las juntas o grietas causadas por la deflexión de la losa bajo la acción de cargas pesadas.	Sellar grietas y juntas; Sellar la base
Escamaduras, grietas tipo mapeo y cuarteaduras [Losas]	Las grietas tipo mapeo o cuarteaduras determinan una red de grietas finas o fisuras, que se extienden sólo por la parte superior de la superficie del hormigón.	B:No reparar. M:Parchar a profundidad parcial; Reemplazar la losa. A:Reemplazar la losa.
Escalonamiento [Losas]	Es una diferencia de nivel en la junta o grieta, causada por solevantamiento o consolidación.	B:No reparar. M:Pulir la superficie de la losa. A:Pulir la superficie de la losa; Reemplazar la losa.
Grietas en bloque [Losas]	Las grietas interconectadas son aquellas que rompen la losa en cuatro o más partes, debido a sobrecargas y/o un soporte inadecuado. Este deterioro se presenta en su mayor nivel de severidad, como se explica más abajo, cuando las losas se han destrozado.	B:Sellar grietas. M:Sellar grietas; Parchar a profundidad total; Reemplazar la losa. A:Parchar a profundidad total; Reemplazar la losa.
Astillamiento en juntas [Losas]	Este deterioro se presenta como la rotura de los bordes de la losa, dentro de una distancia de 60 cm respecto de la junta.	B:No reparar. M:Parchar a profundidad parcial. A:Parchar a profundidad parcial.

**Table 2.2 Deterioros típicos de pavimentos de hormigón (Continuación).**

Deterioro/ Unidad Medida	Descripción	Opciones de Reparación Según grado de severidad
Astillamiento de esquina [Losas]	El astillamiento (o desconche) de esquina esla rotura de la losa, dentro de una distancia de aproximadamente 60 cm de su esquina.	B:No reparar. M:Parchar a profundidad parcial. A:Parchar a profundidad parcial.

Fuente: DAP (2002). Manual de deterioros característicos en hormigón.

Nota: según el grado de severidad considere, B=Baja; M=Media y A=Alta.

## Indicadores estructurales del pavimento

### Pavement Condition Index (PCI)

El método utilizado para evaluar el estado superficial del pavimento es el método PCI, desarrollado por el U.S Army Corps of Engineers y posteriormente adoptado por la FAA. El PCI entrega una calificación acerca de la condición actual de pavimentos flexibles y rígidos a partir de los deterioros observados en la superficie, indicando también su integridad estructural y la condición operativa de la superficie. Sin embargo, no mide la capacidad estructural del pavimento, ni tampoco una medición directa de rugosidad general o de los coeficientes de fricción del pavimento.

El PCI es un indicador numérico de evaluación del pavimento que varía desde 0, condición totalmente fallado, hasta 100, en condiciones perfectas del pavimento. Esto permite clasificar el estado del pavimento de acuerdo a ciertos umbrales definidos por la institución a cargo de la mantención de los pavimentos. En la tabla 2.3, se indica la clasificación indicada por la FAA y adoptada por la DAP.

Tabla 2.3: Estado de los Pavimentos, según valor de PCI (FAA).

Valor PCI	Clasificación
85-100	Excelente
70-85	Bueno
55-70	Regular
40-55	Malo
25-40	Muy Malo
10-25	Crítico
0-10	Fallado

Fuente: FAA, AC150/5380-7B (2014).

Para calcular el PCI es necesario definir en principio la red, ramas y secciones. Donde la red corresponde al conjunto completo de pavimentos asociados a un aeropuerto o conjunto de ellos; La

rama, una parte fácilmente identificable de la red que tiene una función específica como la pista, calle de rodaje paralelo y plataforma ; mientras que la sección, es la parte de la rama que comparte misma características en cuanto a la estructura del pavimento, tránsito, edad, etc. Que la haga diferente al resto. Por su parte, cada sección es dividida en unidades muestrales, de acuerdo al tipo de pavimento:

- pavimentos de asfalto:  $450 \pm 180m^2$
- pavimentos de hormigón:  $20 \pm 8losas$

La cantidad de unidades muestrales mínimas a inspeccionar estará dada por la cantidad que asegure un 95% de confiabilidad , dada por la ecuación 2.1

$$n = \frac{N \cdot s^2}{((e^2/4) \cdot (N - 1) + s^2)} \quad (2.1)$$

Donde:

$e$ = error aceptable en la estimación de PCI de la sección. Frecuentemente  $\pm 5$  puntos PCI

$S$ = desviación estándar de una unidad de muestra. Al realizar la inspección inicial se asume 10 para pavimento de asfalto y 15 para pavimentos de hormigón.

$N$ = número total de unidades muestrales de la sección.

Luego, se debe evaluar en cada unidad el tipo de deterioro, la cantidad y nivel de severidad; de acuerdo a la metodología descrita por la norma ASTM D 5340. En la Figura 2.1, se presenta una planilla tipo de registro de deterioros de pavimentos de asfalto que incluye la información mínima para el cálculo de PCI en pavimentos de asfalto.

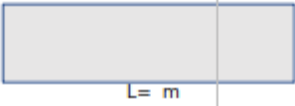
METODO DE EVALUACION DEL INDICE DE CONDICION DEL PAVIMENTO (PCI) PAVIMENTO CON SUPERFICIE ASFALTICA										
HOJA DE REGISTRO							 A= m L= m			
RED:				UNIDAD DE MUESTRA:		$m^2$				
RAMA:				ÁREA DE MUESTREO:						
EVALUADOR (ES):				FECHA DE EVALUACION:						
1. Grieta piel de cocodrilo		6. Erosión por chorro de turbina		11. Agregados púldo						
2. Exudación		7. Reflexión de juntas PCC		12. Peladura						
3. Agrietamiento en bloque		8. Fisuras long. Y transv.		13- Ahuellamiento						
4. Ondulación		9. Derrame de Combustible		14- PCC expuesto						
5. Depresión		10. Ba cheos		15- Fisura por Deslizamiento						
16- Hinchamiento										
DETERIORO	SEVERIDAD	CANTIDAD					TOTAL	DENSIDAD	VALOR DEDUCIDO	
OBSERVACIONES:							TOTAL VALOR DEDUCIDO			
#	VALORES DEDUCIDOS					TOTAL VALORES DEDUCIDOS	q	VALOR DEDUCIDO CORREGIDO (VDC)		
Simbología niveles de severidad:		Alta (H ); Medía (M); Baja (L)				MAX VDC				
						PCI=100- Max VDC				

Figura 2.1: Planilla de Registro de deterioros, método PCI.  
 Fuente: Adaptación ASTM D 5340.

Una vez registrados los diferentes tipos de deterioros en cada unidad muestra inspeccionada, se debe calcular el valor de PCI por unidad de muestra tomando en consideración el tipo de pavimentos y las correcciones correspondiente de los valores deducido, calculados en función del tipo de deterioro la severidad y la cantidad. Ver Figura 2.2, con gráfico de deducción de referencia.




Figura 2.2: Curvas de deducción para deterioro piel de cocodrilo.  
Fuente: ASTM D 5340.

Finalmente, el valor de PCI obtenido en la unidad muestral, se debe promediar con los valores de PCI por sección para obtener un valor global de la sección. Para más detalle sobre el proceso de cálculo de PCI revisar Anexo A.

### Structural Condition Index (SCI)

Es un indicador de pavimento, que se desprende del PCI, pero que intenta capturar el daño causado por el tránsito y la carga. Se calcula bajo el mismo procedimiento del PCI (ASTM D 5340), sin embargo, solo se consideran los siguientes deterioros:

- Agrietamiento tipo Cocodrilo
- Ahuellamiento
- Agrietamiento de esquina
- Agrietamiento transversal
- Agrietamiento generalizado
- Agrietamiento por retracción
- Desprendimiento de juntas
- Desconchado de esquina

## **Indicadores Funcionales del pavimento**

Actualmente, la FAA en la circular AC 150/5380-9 aborda las directrices y procedimientos para medir la rugosidad del pavimento de los aeropuertos. Facilitando el programa ProFAA para analizar dicha rugosidad en término de los siguientes índices: Boeing Bump, Straigh Edge, International Roughness index, California Profilograph y RMS Bandpass. Los cuales son descritos a continuación.

### **Boeing Bump Index (BBI)**

El Boeing Bump Index, es un indicador de rugosidad para del pavimento de pistas en servicio y es usado para identificar 2 tipos de irregularidad: un evento aislado, donde se produce un cambio de elevación en el pavimento en una distancia menor de 100 metros, sintiendo una sacudida repentina la tripulación y aeronave; eventos múltiples, que presentan desviaciones del perfil superficial generando fatiga en los componentes del avión, reduciendo las acciones de frenado, molestia en pasajeros, entre otros (Kohler, 2014).

Para calcular el BBI, se realiza una medición entre 2 puntos del perfil longitudinal de una pista, comparando la longitud de onda de un evento de rugosidad ("Bump Length") versus su amplitud máxima ("Bump Height"). Estas mediciones consideran largos de 120 metros y se rigen por la circular AC 150/5380-9 de la FAA. Aunque inicialmente fue introducida por la compañía Boeing, para ayudar a sus clientes a tener una mejor calidad de viaje.

De acuerdo a los valores del Bump Legth y Bump Height, se determina si un pavimento posee una rugosidad aceptable, excesiva o inaceptable. Ver figura 2.3.




Figura 2.3: Clasificación de estado de los pavimentos, de acuerdo al BBI.

Fuente: Circular AC 150/5380-9.

A pesar de la aceptabilidad del BBI, algunos autores como Gerardi (2015), recomiendan complementar su uso con otros indicadores de rugosidad, ya que demostró en un caso de estudio que el BBI a pesar de estar en condición aceptable, estaba otorgando a pilotos una mala experiencia en la conducción. Demostrando bajo la simulación de una aeronave Boeing 737-800 a 185 km/h, que las aceleraciones experimentadas en el centro de gravedad de la aeronave (0.79g) eran bastante menores a la experimentada en la estación de piloto (1.42g). Lo que en consecuencia afecta a la calidad de la conducción y requiere ser medido.

### Straigh Edge

Este índice se utiliza para evaluar la lisura de pavimentos, e indica el desnivel vertical promedio entre la superficie del pavimento y la de una regla recta de longitud previamente definida, por lo general 5 m.

Para pavimentos nuevos de pistas en aeropuertos, existen criterios de aceptación basados en la circular Circular AC 150/5370-10B “Standard for Specifying Construction for Airport” de la FAA. En la que se considera para la lisura, una desviación máxima de 6 mm en una distancia de 5 m, para cualquier punto del pavimento.

## **International Roughness Index (IRI)**

El IRI, fue desarrollado por el Banco Mundial en 1982 Brasil (Sayers, 1986), como un estándar estadístico de la rugosidad y sirve como parámetro de referencia en la medición de la calidad de rodadura de un pavimento (Marcobal et al., 2017).

El cálculo matemático de dicho índice está basado en la acumulación de desplazamientos en valor absoluto de la masa superior con respecto a la masa inferior de un modelo concreto de vehículo, dividido entre la distancia recorrida sobre el pavimento, cuando el vehículo viaja a 80 km/hr (Sánchez and de Solminihac, 2012) .

La escala del IRI abarca desde el valor 0, que indicaría un pavimento absolutamente perfecto, hasta el 20, que correspondería al caso de una carretera sin pavimentar con erosiones y deformaciones profundas. Para el caso concreto de pavimentos aeroportuarios, las exigencias indican que debe estar comprendido entre 0 y 2 m/km. Sin embargo, su valor no es mandatorio para recibir un pavimento recién construido en la normas de la FAA (Montoya et al., 2016) . En la Figura 2.4 , se indica la clasificación funcional de los pavimentos propuestos por el Banco Mundial para los diferentes usos de pavimentos.




Figura 2.4: Escala estándar IRI del Banco Mundial.  
 Fuente: Karamihas and Sayers (1998)

### California Profilograph Index (PI)

Este indicador se define como la medida, en m/km, de las irregularidades superficiales del pavimento que pueden ocasionar vibraciones excesivas. Para su medición se emplea el perfilógrafo de estructura tipo California que está regulado por la norma ASTM E 1274 “Standard Test for Measuring Pavement Roughness Using a Profilograph”. Definiéndose en la misma que para pavimentos aeroportuarios el PI debe ser inferior a 0,11 m/km.

La forma de obtener el PI, consiste en obtener un perfil de la irregularidad del pavimento e identificar y registrar las zonas en que los sensores detectan una diferencia entre el aparato y la superficie del pavimento superior a 10 mm. El siguiente paso es sumar los desniveles hallados por tramo y obtener el valor de PI, según la ecuación 2.2.

$$IP = \frac{\sum h}{L} \cdot 10 \quad (2.2)$$

Donde:

$IP$  = índice del subtramo, (m/km)

$\sum h$  = suma de las longitudes de las irregularidades en el subtramo

$L$  = Longitud del subtramo




Figura 2.5: Procedimiento medición de irregularidades.  
Fuente: (NIT-SCT, 2006)

### Coefficiente de rozamiento de pista

El coeficiente de fricción es definido por la OACI como la fuerza tangencial necesaria para mantener un movimiento relativo uniforme entre las superficies de contacto y la fuerza normal.

En términos de seguridad, es de vital importancia que los pavimentos de pistas cuenten con un coeficiente de fricción mínimo para asegurar que las aeronaves puedan realizar las operaciones de despegue y aterrizaje, tomando en cuenta que se realizan a velocidades elevadas y que a diferencia de los pavimentos de carreteras, los pilotos no pueden disminuir la velocidad para aumentar el margen de seguridad (White, 2017).

En Chile, los pavimentos de aeropuertos miden el coeficiente de rozamiento con equipos de medición continua con algún equipo de humectación automática, según las indicaciones de la Dirección de Aeronáutica Civil (DGAC). Para cada equipo de medición de rozamiento se definen en umbrales o niveles de rozamiento, algunos de estos niveles se indican en la Tabla 2.4, según las normas aeronáuticas (DAN) 14-154 de la DGAC.

Tabla 2.4: Niveles de rozamiento.

Equipo de Ensayo	Presión del Neumático del Ensayo	Velocidad del Ensayo	Nivel de Diseño	Nivel de Rozamiento para Mantenimiento	Nivel Mínimo de Rozamiento
Remolque medidor del valor Mu	70	65	0.72	0.52	0.42
		95	0.66	0.38	0.26
Deslizómetro	210	65	0.82	0.6	0.5
		95	0.74	0.47	0.34
Vehículo medidor del rozamiento en la superficie	210	65	0.82	0.6	0.5
		95	0.74	0.47	0.34
Vehículo medidor del rozamiento en pista	210	65	0.82	0.6	0.5
		95	0.74	0.54	0.41
Vehículo medidor del rozamiento TATRA	210	65	0.76	0.57	0.48
		95	0.67	0.52	0.42
Remolque medidor de asimiento GRIPTESTER	140	65	0.74	0.53	0.43
		95	0.64	0.36	0.24

Fuente: Adaptación DAN 14-154.

En la Tabla 2.4, se identifican 3 niveles de rozamiento: el nivel de diseño, define el umbral mínimo de rozamiento para pistas de pavimentos nuevos o repavimentados; el nivel de rozamiento para mantenimiento, establece el umbral para comenzar actividades de mantenimiento; y nivel mínimo de rozamiento, es el valor mínimo que puede tener una pista existente, por ende se deben iniciar actividades urgentes de corrección.

Respecto a la periodicidad en las mediciones, la OACI establece cierta frecuencia en base a las operaciones de aviones turbo-reacción y su masa, ver Tabla 2.5. Mientras que en cuanto al lugar de medición, la FAA en la circular AC 150/5320-12C, recomienda mediciones en la zona transversal de la pista dentro de los 3 y/o 6 metros de la línea central de la pista, dependiendo del fuselaje de la aeronave.

Tabla 2.5: Programa de evaluación de rozamiento.

Aterrizajes diarios de aviones turborreacción por pista	Masa anual de aviones por pista [ $10^6 kg$ ]	Periodicidad mínima de inspección de rozamiento
Menos de 15	Menos de 447	Una vez al año
De 16 a 30	De 448 a 838	Una vez cada 6 meses
De 31 a 90	De 839 a 2404	Una vez cada 3 meses
De 91 a 150	De 2405 a 3969	Una vez al mes
De 151 a 210	De 3970 a 5535	Una vez cada 2 semanas
Más de 210	Más de 5535	Una vez por semana

Fuente: OACI-Doc.9137-AN/898 (2002).

### 2.1.2 Necesidades de Mantenimiento y Tratamientos de conservación

La necesidad de mantenimiento de los pavimentos surge cuando el estado de los pavimentos es inferior a lo preestablecido por las agencias de mantenimiento. Resultando esencial conocer el estado del pavimento por medio de técnicas de evaluación, y definir los límites aceptables de servicio y/o seguridad. Asimismo, niveles de servicio más altos implican necesidades de mantenimiento mayor (Hajek, 2011).

En aeropuertos, con frecuencia los niveles de servicio se expresan en términos de PCI, aún cuando las agencias pueden emplear otros indicadores. Al mismo tiempo, el nivel de servicio dependerá de la instalación aeroportuaria, del tamaño y tipo de aeropuerto, tamaño de la aeronave y número de operaciones, tipo de pavimento (Hajek, 2011).

Estos niveles de servicio o estándar de mantenimiento, se encuentra constituido por estrategias y políticas de mantenimiento. Las estrategias, definen las actividades de mantenimiento de los pavimentos y las políticas los niveles de activación del tratamiento. Por lo demás, el proceso de determinación de las actividades M&R se harán tomando en cuenta el presupuesto disponible.

Los pasos necesarios, para identificar las necesidades de mantenimiento a nivel de una red de aeropuertos sería la siguiente:

- Identificar las secciones de pavimento que requieren mantenimiento de acuerdo al nivel de servicio o nivel de activación.
- Selección de tratamiento para las secciones identificadas en el paso anterior.
- Estimación de los costos de aplicación de los tratamientos.
- Priorización de los proyectos verificar si el coste de los tratamientos, supera el presupuesto

disponible. En caso de superar, hacer análisis objetivo de costos y beneficio, y aplicar herramientas de optimización para seleccionar mejor alternativas de mantenimiento.

En cuanto a los tratamientos de conservación de pavimentos, existen múltiples catálogos con información disponible para su uso (Shatnawi et al., 2005; Caltrans, 2008; MDOT, 2010; ODOT, 2001; MnDOT, 2009; Hicks et al., 1999). Su finalidad es mejorar el estado del pavimentos y en algunos casos alargar su vida útil. La Tabla 2.6, recoge los tratamientos de conservación más usados en aeropuertos.

Tabla 2.6: Tratamientos de conservación típicos según tipo de pavimento.

Ambos Tipos de Pavimentos	Pavimentos de Asfalto	Pavimentos de Hormigón
	Sellado y relleno de grietas (con selladores aplicados en frío o en caliente)	
	Parches en áreas pequeñas (usando mezcla caliente, mezcla fría o material patentado)	Sellado de juntas y fisuras (con bituminoso, silicona o selladores de compresión)
	Parcheo por pulverización (sellado manual de virutas o parchado mecanizado por pulverización)	Reparaciones de profundidad parcial (con aire acondicionado, PCC o materiales patentados)
	Parchado a máquina con material AC	
Texturización mediante granallado controlado	Rejuvenecedores y selladores	Reparaciones en profundidad (con aire acondicionado, PCC o materiales patentados)
Rectificado de diamantes	Texturización mediante fresado fino	Parchado a máquina usando mezcla caliente
Microsuperficies ( Microsurfacing)	Tratamiento superficial (sello de viruta, viruta Abrigo de foca)	Estabilización de losas y losas
	Sello de lechada	Transferencia de carga
	Recubrimiento de mezcla en caliente incluye fresado de pavimentos AC)	Costuras de grietas y juntas
	Reciclaje in situ en caliente	Superposiciones de mezcla en caliente
	Reciclaje en frío in situ	Superposición de PCC adherida
	Whitetopping ultrafino	

Fuente: (Hajek, 2011)

Respecto a estos tipos de tratamiento, en la Tabla 2.7 y 2.8, Hajek (2011) recoge los resultados de una encuesta realizada a 50 agencias administradoras de aeropuertos en Estados Unidos, consultando sobre el uso y efectividad de estos tratamientos, destacando los siguientes puntos :

- En mantenimiento rutinario, el 84% de las agencias en pavimentos de asfalto indica usar sellado de grietas vertido en caliente. Mientras que en hormigón, un 61% usa de tratamiento sellado de juntas con silicona.

- En cuanto a tratamientos de M&R, para pavimentos de asfalto los siguientes tratamientos fueron usado por menos del 15% de las agencias: parcheo por aspersión, texturización usando fresado, microsurfacing, reciclaje en el lugar en frío y caliente. En tanto que para pavimentos de hormigón, los tratamientos menos usados son: tratamientos de restauración de transferencia de carga usando subsellado y cosido de losas, reparaciones de profundidad completa usando paneles prefabricados y micro-superficie.
- Para mejorar la confiabilidad de la encuesta, la cantidad de la muestra considerada debiese ser mayor e incluir otros aspectos asociado al clima y la instalación aeroportuaria (pista, calle de rodaje y plataforma).

Tabla 2.7: Resultados encuesta efectividad y uso tratamientos para pavimentos de asfalto.

Tipo de Tratamiento	Detalle	Uso %			Desempeño %		
		Rutina	Ha Intentado	Total	Muy bien	Bien	Mal
Sellado y relleno de grietas	Con sellador aplicado en caliente	84	11	95	19	71	10
	Con sellador aplicado en frío	9	7	16	17	66	17
Parches en áreas pequeñas	Mezcla caliente	52	16	68	42	58	0
	Mezcla fría	43	18	61	13	50	37
	Material patentado	9	11	20	25	50	25
Parcheo por pulverización		5	7	11	0	100	0
Parcheado a máquina con material AC		27	14	41	39	55	6
Milling and machine patching with AC		34	18	52	39	61	0
Texturización usando	Fresado fino	7	5	11	20	80	0
	granallado controlado	0	16	16	0	71	29
Rejuvenecedores y selladores		30	23	52	23	59	18
Tratamiento superficial		15	18	43	6	81	13
Sellado de Lechada		23	25	48	10	75	15
Microsurfacing		2	9	11	25	75	0
Recubrimiento de mezcla en caliente		45	23	68	48	48	4
Recubrimiento de mezcla en caliente Incluye Fresado		45	18	64	58	42	0
Reciclaje in situ en caliente		5	2	7	N/A	N/A	N/A
Reciclaje in situ en frío		2	0	2	N/A	N/A	N/A
Whitetopping (superposición de PCC)		7	7	14	60	20	20

Fuente: (Hajek, 2011)

N/A: el tamaño de la muestra es demasiado pequeño.

Tabla 2.8: Resultados encuesta efectividad y uso tratamientos para pavimentos de hormigón.

Tipo de Tratamiento	Detalle	Uso %			Desempeño %		
		Rutina	Ha Intentado	Total	Muy bien	Bien	Mal
Sellado de juntas y fisuras	bituminoso	29	15	44	13	80	7
	Silicona	39	22	61	29	71	0
	Selladores de compresión	7	22	29	36	36	27
Restauración de transferencia de carga	sub-sellado y levantamiento de losas	2	5	7	N/A	N/A	N/A
	costura de losa	2	5	7	N/A	N/A	N/A
	reacondicionamiento de Barras	12	5	17	60	40	0
Reparación de parche poco profundo usando	PCC	34	15	49	28	67	6
	AC	29	20	49	18	65	18
	Material patentado	17	17	34	42	42	17
Reparaciones de profundidad total y parcial o reemplazo de losas usando	PCC	46	15	61	47	47	6
	AC	20	39	59	31	54	15
	Material patentado	7	17	24	30	50	20
	Prefabricados	2	2	5	N/A	N/A	N/A
Parcheo de máquina con AC		5	12	17	33	50	17
Rectificado de diamantes		5	34	39	21	79	0
Granallado controlado		0	15	15	0	80	20
Microsurfacing		0	5	5	N/A	N/A	N/A
Recapado AC		10	27	37	36	64	0
Superposición de PCC adherida (whitetopping)		7	15	40	40	20	20

Fuente: (Hajek, 2011)

N/A: el tamaño de la muestra es demasiado pequeño.

Por último, es importante señalar que la elección de tratamientos irá en línea con la tecnología disponible por las agencias, incluyendo el personal capacitado y recursos económicos. Además de las necesidades geográficas del emplazamiento de la instalación aeroportuaria.

## 2.2 SGPA en Chile: Estado de la práctica

En esta sección se señalan los antecedentes recopilados sobre el SGPA en Chile y sobre las componentes desarrolladas en el convenio de la DAP y la Universidad Técnica Federico Santa María. El objetivo de esta sección, es entregar una revisión detallada sobre el funcionamiento y las necesidades de mejora del actual SGPA, con el fin de poner en contexto esta investigación.

### 2.2.1 Antecedentes

La DAP es la institución encargada de cubrir las necesidades y demandas de la infraestructura aeroportuaria del país, organizando mecanismos de planificación para responder a las necesidades totales de la red, dándole seguimiento al estado de pistas, plataformas, calles de rodaje, etc; para asegurar la seguridad de las operaciones. Asimismo, la DAP contribuye al desarrollo de infraestructura de Pequeños Aeródromos, facilitando la conectividad e integración territorial de las zonas más aisladas del país.

En este contexto, la DAP debe hacerse cargo de la administración de recursos fiscales, para tareas de conservación, rehabilitación, construcción y expansión de la red. Estimándose que alrededor del 40% del presupuesto total en el período 2012-2018 era destinado a tareas de conservación (Tolmo, 2020). Existiendo una preocupación por evitar la acumulación de actividades conservación y particular de rehabilitación que suponen una restricción estricta de los presupuesto.

Para facilitar la toma de decisiones las instituciones aeroportuarias encargadas de la administración de los pavimentos deben contar con herramientas para: evaluar las necesidades de pavimento, optimizar la selección de proyectos y tratamientos durante un período de varios años, y analizar los impactos a largo plazo de las prioridades de sus proyectos. Sin embargo, históricamente las decisiones sobre mantenimiento y rehabilitación en Chile se han basado en la experiencia y la mejor práctica de ingeniería, con algunos intentos de implementar algunas herramientas de priorización (Rojas, 2017).

Actualmente La DAP gestiona 106 complejos aeroportuarios distribuidos de la siguiente manera (DAP, 2021):

- **Red primaria:** Principales aeropuertos del país, permiten la conectividad nacional e internacional. Constituido por 16 aeropuertos, entre ellos 7 con conectividad internacional y 9 nacional. Ver Figura 2.6.
- **Red secundaria:** son aquellos que sirven de apoyo a la Red principal y centralizan el movimiento aéreo de las regiones.
- **Pequeños aeródromos:** la infraestructura principal son pistas entre 700 y 1.000 metros de longitud, para ser usadas por aviones pequeños como servicio eventual. Con el fin de dar acceso a ciertas regiones que no cuentan con otro medio de comunicación; cumpliendo un rol de carácter social antes que económico.



Figura 2.6: Red de Aeropuertos y pequeños Aeródromos de Chile.  
Fuente: Dirección de Aeronáutica Civil.

### 2.2.2 Avances en la implementación del SGPA Actual

La implementación de un SGPA requiere de una serie de actividades que incluyen (Tighe and Covalt, 2008): el análisis de usuario y sus necesidades; un inventario del estado de los pavimentos; evaluación de los pavimentos; herramientas de procesamiento de la información y bases de datos,

software personalizados; soporte continuo y actualización del SGPA.

En las siguientes secciones se presentarán algunos componentes desarrollados del SGPA en Chile. Incluyendo además aquellos que se encuentran en envías de desarrollo dentro del convenio de colaboración entre la Universidad Técnica Federico Santa María y la DAP.

## Marco Teórico funcionamiento SGPA

Tolmo (2020), elaboró un marco teórico para la implementación de un SGPA para la red de aeropuertos chilenos, ver Figura 2.7; considerando 4 módulos esenciales para su funcionamiento: base de datos, metodologías, procesos y resultados; acompañados de aspectos técnicos, económicos, ambientales y sociales. Una breve descripción de estos módulos, es indicada a continuación:

- **Base de Datos:** El proceso parte con el ingreso de información al sistema y que será almacenada en la base de datos. La que a su vez incluye información de inventario, condición del pavimento, estructura, historial de M&R, tráfico aéreo y clima. Esta información servirá para alimentar a diferentes procesos del SGPA y requiere mantenerse actualizada por lo diferentes actores participes del sistema.
- **Metodologías:** alimentan ciertos procesos del sistema con procedimientos, objetivos e información para su funcionamiento. Distinguiendo las siguientes metodologías:
  - Criterios estratégicos: metas u objetivos para la conservación de los pavimentos aeroportuarios, ayuda a definir necesidades de mantención de los pavimentos.
  - Matriz de activación del tratamiento: concentra estándares de mantenimiento, tratamientos y límites en que son aplicables. Señala el estado que desencadena cierta actividad de mantenimiento.
  - Matriz de Optimización: incluye información relacionada con beneficios, costos, criterios ambientales y sociales, tras efectuar determinado tratamiento de conservación. Útil para seleccionar tratamiento óptimo.
  - Modelos de Desempeño: algoritmos y recomendaciones para predecir la condición del pavimento en el tiempo.
- **Procesos:** llevan a cabo las tareas del SGPA en forma sistemática y cada uno de ellos se describen a continuación, en este mismo orden correlativo:
  - Definición de familia de pavimentos: Agrupación de secciones de pavimento con similares características, ya sea tipo de pavimento, tráfico soportado, clima, entre otros. Con el fin de proveer acciones de mantenimiento comunes para pavimentos similares.

- Análisis de Necesidades: identificar si el pavimento requiere mantención, rehabilitación o reconstrucción. Según criterios estratégicos definidos por los gestores de pavimentos.
  - Selección de conservación e identificación de tratamientos: De acuerdo a la evaluación del pavimento, se identifican los pavimentos que requieren tratamientos de emergencia, menor, rutinaria o mayor. Identificando los tratamientos aplicables en cada situación, generando un informe para todos los pavimentos.
  - Selección de tratamiento óptimo: Se basará en los criterios establecidos por los administradores de pavimento, ya sea : técnicos, económicos, ambientales, sociales, entre otros. Finalizando el proceso, con la identificación del tratamiento óptimo a aplicar en cada sección en estudio.
  - Priorización: este proceso arroja una lista de secciones a conservar en un orden definido (Ranking), basado al igual que en procesos anteriores en criterios económicos, sociales, políticos, ambientales, etc; definidos por los administradores del sistema de pavimentos.
  - Selección de proyectos & proyección: En base a la disponibilidad de presupuesto, se seleccionan proyectos de mantenimiento, rehabilitación y/o expansión para cubrir las necesidades de la red hasta agotar el presupuesto. Este análisis se realiza a largo plazo, usando las proyecciones de modelos de desempeño para simular el estado de la red.
- **Resultados:** informe del estado de la red, con listado de priorización de pavimentos; incluye alternativas óptimas de mantenimiento.

Por otro lado, Tolmo (2020) hace una serie de recomendaciones para el desarrollo de las componentes del marco teórico propuesto, entre ellas se destacan:

- Definir las políticas, los umbrales y estrategias de mantenimiento para el SGPA propuesto por parte de la DAP. Proponiendo una Matriz de activación del tratamiento.
- Para la optimización se recomienda el enfoque secuencial que resuelve la asignación del tratamiento óptimo y a posterior los pavimentos a intervenir.

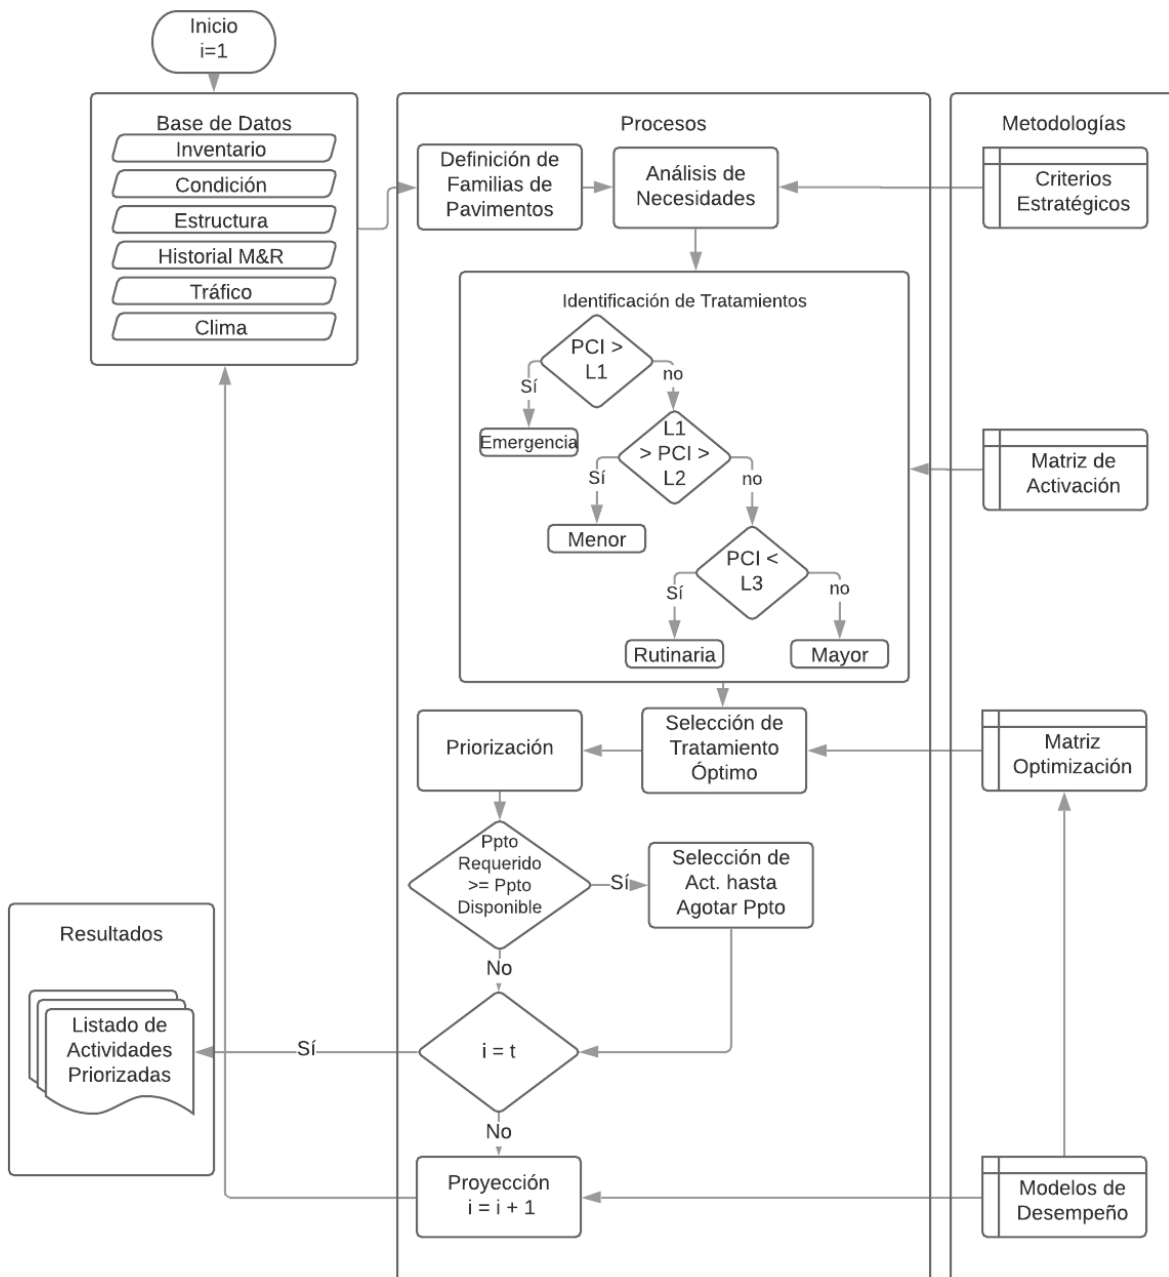


Figura 2.7: Marco Teórico para la Gestión de Pavimentos Aeroportuarios en Chile.  
Fuente: (Tolmo, 2020)

## Base de Datos

Dentro del convenio de investigación de la DAP y la Universidad Técnica Federico Santa María, Alvarez (2020) recopiló datos sobre la red nacional de aeropuertos de Chile y propuso una estructura de almacenamiento de datos en función de las necesidades de implementar un SGPA. En esta investigación identificó 2 falencias principales en los procesos de almacenamientos. La primera, era la falta de una plataforma centralizada, donde registrar la información, y la segunda, la ausencia de protocolos para almacenamiento de datos. Para ello propone una serie de definiciones y procedimientos para estructurar una base de datos en la DAP y la implementación y registro de esta en el software Maximo Asset Management.

Maximo ASsset Management es un software de gestión de activos, recomendado por la DAP, y entre sus ventajas se haya que: facilita una vista comprensiva de los datos, se caracteriza por ser adaptable a la necesidad de los usuarios y el Ministerio de Obras Públicas posee una licencia para su uso, por lo que no significa un costo extra de adquisición en los presupuestos de la institución.

Alvarez (2020) propone una estructura de 5 categorías principales y a su vez éstas se conforma de subcategorías para facilitar el actualización y orden de los datos (ver Tabla 2.9); basadas en los lineamientos de organismos internacionales como al FAA (Federal Aviation Administration) y la OACI (Organisation de l'Aviation Civile Internationale); y que a su vez pudiese satisfacer los requerimientos del SGPA que se pretende implementar en Chile.

Tabla 2.9: Estructura de base de datos propuesta por (Alvarez, 2020).

<b>Categorías</b>	<b>Subcategorías</b>
Inventario de la Red	Componentes de la Red; Información General; Especificaciones; Ubicación; Propiedades Sección; Pista.
Estructura de Pavimentos	Información de Capas; Capacidad Estructural.
Historial de MR	Listado de Proyectos; Obras Realizadas.
Condición de los Pavimentos	Listado PCI por Sección; Listado por Unidad Muestral; Deterioros por Unidad Muestral; Coef. de Rozamiento; IRI Pista.
Tráfico y Clima	Información Climática; Demanda Anual por Aeronave

Fuente: (Alvarez, 2020)

Las definiciones sobre las categorías y subcategorías, pueden ser consultadas en la Tabla B.1, anexo B.

## Predicción del desempeño de pavimentos

Actualmente la DAP no cuenta con una herramienta para predecir la condición del pavimento, en términos de PCI, en el tiempo. No obstante, encarga esta tarea a consultores externos que hacen uso de algunos software como MicroPaver para predecir la condición del pavimento. Sin embargo, se desconoce exactamente los procedimientos y supuestos hechos para realizar dichas predicciones; tomando en consideración la relevancia de los modelos de desempeño de pavimentos de aeropuertos para la toma de decisiones, resulta necesario elaborar una metodología que defina que variables y algoritmos utilizar.

Un análisis sobre las predicciones realizadas y una propuesta metodológica es desarrollada en profundidad en los capítulos 4 y 5, respectivamente.

## Priorización y optimización de actividades de M&R

Dentro de las tareas de los SGPA es lograr definir el orden de intervención de los proyectos, en base a una serie de parámetros técnicos, económicos, sustentables, sociales. Actualmente la DAP cuenta con una herramienta denominada Matriz de Priorización, y cuya función es rankear las secciones que requieren mantención y/o rehabilitación dentro de la red primaria de aeropuertos, mediante un índice de priorización formulado por (Rojas, 2017) y que toma en cuenta: las operaciones, uso de la sección y su importancia; ver Tabla 2.10.

Tabla 2.10: Matriz de priorización.

Aérodromo	Despegues Totales Anuales	FO	Rama	FR	Sección	FS	PCI	IP	Ranking
Diego Aracena	14,476	0.88	Plataforma	0.95	PL-8	0.99	47	44	20
Balmaceda	4,405	0.92	Pista	0.85	PI-1	0.9	38	34	6
Balmaceda	4,405	0.92	Rodaje Bravo	0.95	RB-1	0.9	36	33	5
Carlos Ibañez	12,214	0.89	Pista 12-35	0.97	U30-1	0.95	45	42	14
Carlos Ibañez	12,214	0.89	Pista 12-36	0.97	U30-2	0.95	45	42	14
Carlos Ibañez	12,214	0.89	Rodaje Eco	0.95	RE-1	0.9	48	44	20
Arturo Merino Benítez	141,890	0.8	Pista 35R/17R	0.97	U17E7	0.95	32	29	3

Fuente: (Rojas, 2017)

En el índice de priorización (IP), ecuación 2.3, mediante el Factor de Operación (FO), captura el impacto de la actividad aérea por aeropuertos en función de las operaciones realizadas mediante un ajuste logarítmico. En tanto que, el Factor de Rama (FR) esta asociado al uso del pavimento diferenciando entre zonas: prioritarias, que poseen ruta alternativa; urgentes, plataformas con pocos puestos de estacionamientos; y no prioritarias, aquellas pertenecientes a margenes y zonas de protección a chorro. En cuanto al Factor de Sección característica (FC). El valor numérico

asociado a cada factor, se indica en la tablas C.2, C.3 y C.1 (Anexo C), para todos los casos entre menor sea el valor del factor mayor importancia este tiene y viceversa.

$$IP = PCI \cdot \frac{FO \cdot FR \cdot FS}{3} \quad (2.3)$$

Aún cuando el planteamiento del índice de priorización es correcto, aún no ha sido utilizado debido a la falta de un modelo de desempeño capaz de proyectar valores de PCI en el tiempo; sumado a la falta de madurez de un sistema de gestión capaz de integrar matriz de priorización con las alternativas de mantenimiento y herramientas de optimización que asegure los mejores costos y/o beneficios de la red.

Asimismo, actualmente no existe una herramienta de optimización para la selección de tratamientos de mantención que mediante un análisis del ciclo de costo de vida del pavimento pudiese seleccionarse dentro de las alternativas de mantenimiento alguna que maximice el beneficio o minimice los costos. Por ello, urge desarrollar este tema dentro del SGPA, recomendándose usar como punto de partida los múltiples ejemplos de optimización de tratamientos de mantención en pavimentos reportados por la literatura (Camahan et al., 1987; Zhang et al., 2010; Guignier and Madanat, 1999; Zhang et al., 2017b; Noruzoliaee and Zou, 2019; Barua and Zou, 2021; Torres-Machi et al., 2018; Chen and Zheng, 2021).

## **Estrategias y Políticas de Mantención**

Sin lugar a dudas el desarrollo de políticas de mantenimiento que indiquen los criterios bajo los cuales es necesario aplicar las acciones de mantenimiento es esencial para el funcionamiento correcto de un SGPA. Por el momento, las políticas de mantenimiento no han sido definidas, sin embargo, éstas se encuentran contempladas dentro del proyecto de colaboración, esperando definir criterios y/o consideraciones para determinar umbrales para gatillar acciones de mantenimiento para pavimentos aeroportuarios, basados en la experiencia internacional de otros SGPA con mayor madurez.

En cuanto a las estrategias y las respectivas acciones de mantenimiento estas han sido llevada acabo bajo un criterio ingenieril. Sin embargo, es necesario protocolizar los procedimientos y objetivos perseguidos con las actividades de mantenimiento efectuadas, definiendo las estrategias y las operaciones respectivamente. Un punto de partida para esta tarea puede ser la revisión de la literatura sobre el tema , aunque se ha de considerar que las operaciones definidas en cada estrategia se han de ajustar finalmente a los objetivos de cada institución a cargo de la administración de los pavimentos.

## Software

La DAP cuenta con el software MicroPAVER, que posee las capacidades para la gestión adecuada de pavimentos de carreteras, estacionamientos y aeropuertos. Sin embargo, debido a la falta de capacitación y horas hombre para ingresar datos de la red aeroportuaria, este programa quedo en desuso. No obstante a ello, han existido repetidos esfuerzos por contribuir a la mejora en la gestión de los pavimentos de aeropuertos por parte de la DAP, incluyendo el uso de SIGES (Sistema de Gestión de Estado Superficial), que facilitan el procesamiento y el análisis de datos georreferenciados; y Maximo Asset Management, que es un software de gestión de activos que permite almacenar información y realizar algunos procesos de análisis.

No obstante a los esfuerzos realizados en el pasado, es importante contar con un software que permita integrar todas las componentes desarrolladas y en desarrollo, personalizado para cubrir las necesidades de la DAP y que permita la actualización de bases de datos y herramientas necesarias en un futuro.

### 2.2.3 Desafíos en la implementación del SGPA en Chile

A partir de un análisis detallado sobre el estado de la práctica de la implementación de un SGPA en Chile, algunos desafíos por cumplir es:

- Designar una unidad a cargo de la administración del SGPA, encargada de la alimentación y actualización de la base de datos, procedimientos y retroalimentación de los resultados. Si no se cuenta con la cantidad adecuado de personal la implementación de un SGPA corre el riesgo de fracasar.
- Debe existir un modo de financiamiento definido capaz de cubrir las necesidades de evaluación constante de la red, capacitación de personal, funcionamiento y mantención del SGPA.
- Generar un protocolo de procedimientos, para realizar diferentes tareas para alimentar la base de datos, entre ellos el momento en que efectuar la evaluación de pavimentos.
- Generar o adquirir un Software de gestión de pavimentos, apropiado para integrar los componentes ya desarrollados en el convenio de colaboración entre la Universidad Técnica Federico Santa María y la DAP.

# Capítulo 3

## Modelos de Desempeño de pavimentos

### 3.1 Modelos de desempeño de Pavimentos

Los modelos de desempeño de pavimentos son una herramienta clave para los SGP, cuya función es predecir la condición o algún indicador del estado del pavimento en cualquier momento de su vida útil, con el propósito de planificar las actividades de mantención y rehabilitación en el tiempo (Solminihac et al., 2018). Lo que ayuda a conservar la red de pavimentos en un estándar deseado, ahorra costos y evita la pérdida de valor de los activos de infraestructura (Irfan et al., 2015). Asimismo, los modelos de desempeño son expresados mediante alguna función que involucre múltiples factores como el clima, cargas, calidad de los materiales, entre otros; que tienen relación con la causas que producen el deterioro de los pavimentos.

Para ilustrar el deterioro de los pavimentos y el costo relativo de la rehabilitación en distintos períodos de la vida del pavimento, se presenta la Figura 3.1. En ella se destaca que el deterioro del pavimento progresa muy lentamente en sus primeros años de uso y cualquier costo de mantenimiento para restablecer la condición inicial en esta etapa es reducido. A medida que pasa el tiempo el deterioro llega a una etapa crítica donde la condición del pavimento se reduce bruscamente y el tipo de tratamiento a aplicar es más profundo llegando incluso a la rehabilitación del pavimento. Se estima que el costo de una actividad de preservación y conservación manteniendo el pavimento en buen estado es 4 a 5 veces más barata que rehabilitar un pavimento en mal estado para llevarlo a una condición buena (AC150/5380-7B, 2014).

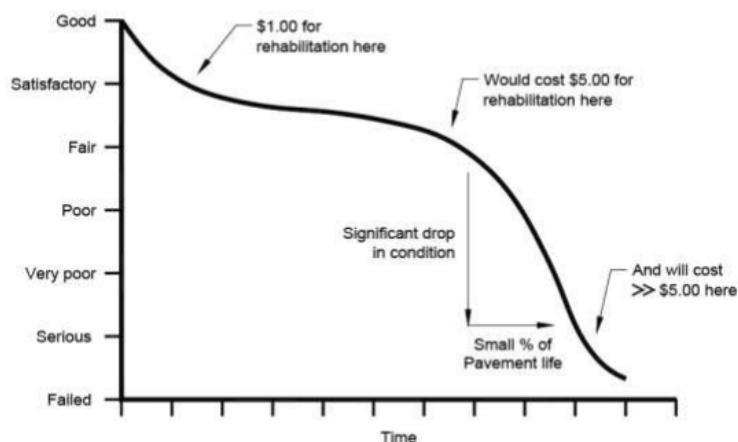


Figura 3.1: Ciclo de vida típico de la condición del pavimento.

Fuente: (AC150/5380-7B, 2014).

Por otro lado, los modelos de desempeño pueden clasificarse desde el punto de vista del análisis información utilizada para su elaboración, en modelos: empíricos, mecanicista o una mezcla de ellos. Los modelos empíricos utilizan datos recogidos de pavimentos existentes; mientras que los modelos mecanicistas se basan en conocer las propiedades físicas y mecánicas, para relacionar esfuerzos y deformaciones con el comportamiento de los pavimentos. Por último, el enfoque empírico mecanicista es una mezcla de ambos.

El indicador de serviciabilidad obtenido de la prueba AASHO, es un ejemplo de modelo empírico; mientras que los modelos de agrietamiento desarrollados por la Guía MEPDG (Mechanistic-Empirical Pavement Design Guide) son empírico mecanicista al incluir mediciones reales de variables explicativas y una ley de fatiga para el cálculo de un índice de daño acumulado, que representa la relación entre carga y daño de una estructura (Moreno et al., 2013).

De la misma forma los modelos de desempeño de pavimentos también se pueden clasificar en deterministas y probabilísticos. Aunque algunos autores han incluido una tercera categoría basados en métodos de soft computing o de inspiración biológica (Yang, 2004; Fathi et al., 2019; Yao et al., 2019), para referirse a técnicas avanzadas de computación basadas en Machine Learning.

El enfoque determinista, estima el indicador o condición del pavimento de forma precisa, relacionando un indicador de deterioro con una serie de variables explicativas del deterioro del pavimento. Por lo general, hace uso de regresiones con funciones de tipo lineal, sigmoidea, entre otras. Mientras que, el enfoque probabilístico estima el indicador o estado de pavimento como una función de probabilidad, indicando posibles estados en el que podría evolucionar el pavimento. Las cadenas de Markov, curvas de supervivencia son ejemplo de modelos probabilísticos. La Tabla 3.1, indica

el uso de los enfoques señalados cualitativamente de acuerdo al nivel de aplicación. Cabe señalar que, el término absoluto hace referencia a que el valor a predecir no depende un valor pasado de la variable a predecir; mientras que el término relativo incluye valores pasados de la variable a predecir.

Tabla 3.1: Uso de técnicas para modelar la condición de pavimentos por nivel de gestión.

Modelos de Desempeño de Pavimentos		Red Nacional	Red Municipal	Nivel Proyecto
Determinista	Absoluto			+++
	Relativo-estructural	++	++	+
	Relativo-funcional	++	++	
Probalístico	Metodología bayesiana	++	++	
	Markov	+++	++	
Híbrido	Redes neuronales artificiales	+	+	+

Fuente: Justo-Silva et al. (2021) . Nota: +++ de uso habitual; ++ de uso común; + de uso menor.

Aunque existen múltiples técnicas para desarrollar modelos de desempeño de pavimentos, el uso de ella dependerá de la cantidad de datos disponibles, de la experiencia local respecto al uso de herramientas de modelación, las políticas y las preferencias de las agencias (Yang, 2004). En las siguientes secciones se describen algunas técnicas usadas en la literatura para elaborar modelos de desempeño, poniendo énfasis en los modelos usando ML en los cuales se basa esta investigación.

### 3.1.1 Modelo basado en opinión de experto

Los modelos basados en opinión de experto se usan en ocasiones que los PMS no poseen información o la información recolectada es deficiente. En tal caso, se recurre a la opinión de expertos para completar información o establecer algunos criterios para elaborar una curva de tendencia de deterioro de los pavimentos. En el departamento de Transporte de Dakota del Sur, se utilizó este enfoque elaborando una curva en base a regresiones a partir de las estimaciones de expertos sobre edad de los pavimentos para alcanzar cierta extensión y gravedad de los deterioros, con la cual obtener valores de deducción para estimar PCI (Zimmerman and Bahulkar, 1998). Otro ejemplo del uso de opinión de experto, es el caso del PMS de Nan-jing, donde se utilizó Cadenas de Markov en base a una Matriz de transición de probabilidades (MTP) estimada por expertos ante la escasez de datos (Qian et al., 2000).

### 3.1.2 Modelo de extrapolación de tendencias

Este modelos se basan en extrapolar de manera lineal la tendencia o razón con que se deteriora el pavimento utilizando los 2 últimos puntos conocidos de la condición del pavimento, a pesar de que no se sabe a ciencia cierta el crecimiento o decrecimiento de la razón de deterioro, ver Figura 3.2 . Este método es preciso para realizar predicciones en períodos cortos de tiempo, asumiendo que las condiciones de carga y tránsito se mantienen igual que en el pasado. Sin embargo, pierde precisión para realizar predicciones en el futuro. Por otro lado, es solo aplicable a secciones particulares y no a una red de pavimentos, dado que las condiciones de carga, capacidad de soporte, clima, entre otros; es diferente (Shahin, 1994).




Figura 3.2: Ejemplo Extrapolación Lineal.

Fuente: Shahin (1994).

### 3.1.3 Modelos de Regresión

El análisis de regresión permite establecer relaciones entre 2 o más variables, mediante alguna función de ajuste lineal, polinomial, sigmoide, etc. Ver Figuras 3.3. Siendo efectivo su uso para modelar secciones específicas de pavimentos que comparten características similares en término del uso, carga, frecuencia, clima, entre otros. Sin embargo, resulta compleja su aplicación a nivel de redes de pavimentos por la gran cantidad de variables que significa (Yao et al., 2019). Por lo demás, el uso de regresiones para modelar problemas complejos y de carácter no lineal, con lleva a un proceso tedioso de transformación de variables de entrada para ajustar las relaciones no lineales del problema (Kargah-Ostadi, 2014).




Figura 3.3: Ejemplo Regresión Lineal

Fuente: Shahin (1994).

Las regresiones han ampliamente utilizadas para el desarrollo de modelos de desempeño de pavimentos (Arambula et al., 2011; Kim and Kim, 2006; Luo, 2013; Chen and Mastin, 2016; Mills et al., 2012). En aeropuertos, Yuan and Mooney (2003) desarrollaron un modelo de desempeño de pavimentos usando regresiones polinomiales de grado 5 sujetas a restricciones de pendiente, utilizando el concepto de curvas de familia de Shahin (1994). En este caso, las variables que resultaron poseer una mayor correlación con el indicador PCI usado para modelar, fueron el espesor, uso del pavimento y la causa de deterioro. Otros estudios con regresiones son lo hechos por Suh et al. (2002), que emplearon regresiones de orden 2 para relacionar el valor de PCI con el uso, acciones de mantenimiento y una variable cualitativa de la velocidad en la sección. Otros modelo hechos por Al-Suleiman et al. (1996); Kwak et al. (2020), consideraron directamente la variable transito aéreo dentro de las variables de la regresión empleando el concepto de aeronave equivalente de diseño descrito en la circular AC 150/5320-6D de la FAA.

Por otro lado, se han propuestos nuevos indicadores de servicio de aeropuertos basado en modelos de desempeño construidos mediante regresiones y que tienen relación con aspectos estructurales y funcionales del pavimento (Ashtiani et al., 2019). En la Tabla 3.2 se indican algunos modelos de desempeño de pavimentos de aeropuertos empleando análisis de regresión.

Tabla 3.2: Compendio de modelos utilizados para la predicción de PCI en pavimentos de aeropuertos.

Autor(es)	Rama	Modelo
Kwak et al. (2020)	Centro de Pista	$PCI = 100 - e^{(3.887+0.043 \cdot Age+0.026 \cdot ADT-0.007 \cdot ST)}$
	Calle rodaje en Paralelo	$PCI = 100 - e^{(-0.455+0.037 \cdot Age+0.186 \cdot ADT)}$
PAVEAIR (2021)	Pista/AC	$PCI = 100 - 3.4467 \cdot Age + 0.063861 \cdot Age^2$
	Calle de Rodaje AC	$PCI = 100 - 3.4149 \cdot Age + 0.082141 \cdot Age^2 - 0.00072445 \cdot Age^3$
Suh et al. (2002)	Pista( Sin M&R)	$PCI = 100 - 1.584 \cdot Age - 0.022 \cdot Age^2$
	Calle de Rodaje (Sin M&R)	$PCI = 100 - 1.6 \cdot Age - 0.045 \cdot Age^2$
Yuan and Mooney (2003)	Pista AC / Load com	$PCI = 100 - 4.3076 \cdot Age - 0.1019 \cdot Age^2 + 0.01949 \cdot Age^3 - 0.0006 \cdot Age^4 + 0.000006 \cdot Age^5$
	Calle de Rodaje/AC/Cargas	$PCI = 100 - 0.7175 \cdot Age^2 + 0.04764 \cdot Age^3 - 0.001 \cdot Age^4 + 0.000005 \cdot Age^5$
Mitchell (2007)	PCC General	$PCI = 100 - 5.39567 \cdot Age - 0.01963 \cdot Age^2 + 0.0036 \cdot Age^3 - 0.0038 \cdot Age^4 + 0.000003 \cdot Age^5$

Fuente: Elaboración propia.

Nota: AC =Pavimento de asfalto; Age =Edad del pavimento; Loadcom =Combinación de cargas; PCC = Pavimento de hormigón.

### 3.1.4 Cadenas de Markov

Las Cadenas de Markov, son procesos estocásticos que se caracterizan por dividir en estados discretos la variable de interés, determinando la probabilidad con que un pavimento pase de un estado a otro dentro de determinado ciclo (tiempo, carga, tráfico) (Shahin, 1994).

Esta técnica requiere de un vector de estado inicial más una MTP elaborada a partir de datos históricos del estado del pavimento, La Figura 3.4 muestra una MTP para el modelo de desempeño de pavimetnos estimado por Camarena et al. (2018). En la literatura se han visto múltiples aplicaciones de este método (Abaza, 2016; Pulugurta et al., 2009; Alimoradi et al., 2020; Hassan et al., 2017; Chamorro et al., 2009; Yang et al., 2006), resaltando la ventaja de que este método es útil cuando la cantidad de datos es acotada, necesitando al menos 2 mediciones con un rango amplio de estados (Osorio-Lird et al., 2018). No obstante, en algunos casos reportados en la literatura se han empleado opiniones de experto, el uso de funciones basado en pocos datos para obtener la MTP y un tercer método suponer la distribución anuales del estado del pavimento (Ortiz-García et al., 2006).

$$\mathbf{P} = \begin{bmatrix}
 81\% & 19\% & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 71\% & 29\% & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 56\% & 44\% & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 37\% & 63\% & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 5\% & 95\% & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0\% & 100\% & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0\% & 100\% & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0\% & 100\% & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0\% & 100\% \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 100\%
 \end{bmatrix}$$

Figura 3.4: Ejemplo MTP  
Fuente: Camarena et al. (2018).

Butt et al. (1994) emplearon los datos de 22 aeropuertos y elaboraron un modelo de desempeño a nivel de pavimentos familiares y zonas que representaban una razón de deterioro constante en un intervalo de 6 años, describiendo una MTP propia en cada nivel a partir de los datos disponible. Qian et al. (2000) en cambio, emplearon la opinión de experto para determinar la MTP del PMS de Nanjing, ante la escasez de datos. Camarena et al. (2018), empleando datos reales del aeropuerto de Cajamarca, Perú; hace uso de regresiones logísticas para proponer una MTP.

Por otro lado, cabe señalar que para usar este método se requiere cumplir con los siguientes supuestos: que la probabilidad de que el proceso pase de un estado a otro, depende únicamente del estado actual y no de estados pasados; el tiempo es discreto, se definen estados en un espacio finito; y que el cambio de estado está definido por un conjunto de probabilidades (Solorio Murillo et al., 2014).

### 3.1.5 Modelos basado en Algoritmos de Machine Learning

#### Machine Learning

ML es una rama de la inteligencia artificial, definida como el campo de estudio que permite a las computadoras aprender sin estar programadas explícitamente (Samuel, 1959). En este contexto, el algoritmo aprende las complejas relaciones de los datos de entrada, identificando patrones y tomando decisiones para obtener una salida. Algunas de las tareas que se pueden realizar con estos algoritmos son en problemas de clasificación, predicción y agrupamiento de datos.

Uno de los pioneros de ML es Arthur Samuel quién creo 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 de las redes neuronales artificiales. A pesar de estos avances, no fue hasta mediados del año 2000 que comenzó otro apogeo, según Rejala et al. (2019) esto se debió en gran parte por: la gran cantidad de datos debido a internet; la potencia de cómputo y algoritmos mejorados que fueron optimizados.

Con el tiempo ha surgido una subárea denominada Deep Learning que emplea ANN con una alta cantidad de capas o niveles jerárquicos que son capaces de aprender mejor que modelos más superficiales o con menor cantidad de capas. Estas técnicas sin lugar a dudas han generado 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, entre otros.

A su vez, los algoritmos de ML pueden dividirse en 3, de acuerdo al tipo de aprendizaje. Encontrándose modelos basados en aprendizaje supervisado, no supervisado y con reforzamiento.

En el aprendizaje supervisado el algoritmo se entrena con un set de datos en el que se conoce a priori las respuestas correctas del problema, de tal manera que el algoritmo es capaz de descifrar la relación existente entre las variables de entrada y de salida mediante el ajuste de los parámetros del modelo. La variable objetivo para este tipo de aprendizaje puede ser una variable categórica o continua, asociados a problemas de clasificación y de predicción respectivamente.

El aprendizaje no supervisado es entrenado con un set de datos desconociendo respuestas correctas para el problema en cuestión. En este caso el algoritmo se encarga de identificar o agrupar elementos con cierta similitud. En general los problemas que pueden resolverse con este tipo de aprendizaje son del tipo clustering.

En el aprendizaje por refuerzo no se poseen 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, un ejemplo de esto es generar un programa experto en el juego de ajedrez en el que el algoritmo mapeará las diferentes acciones y seleccionará la que le genere mayor beneficio para ganar.

La figura 3.5, presenta una clasificación de los modelos de ML y algunos algoritmos usados en cada caso.

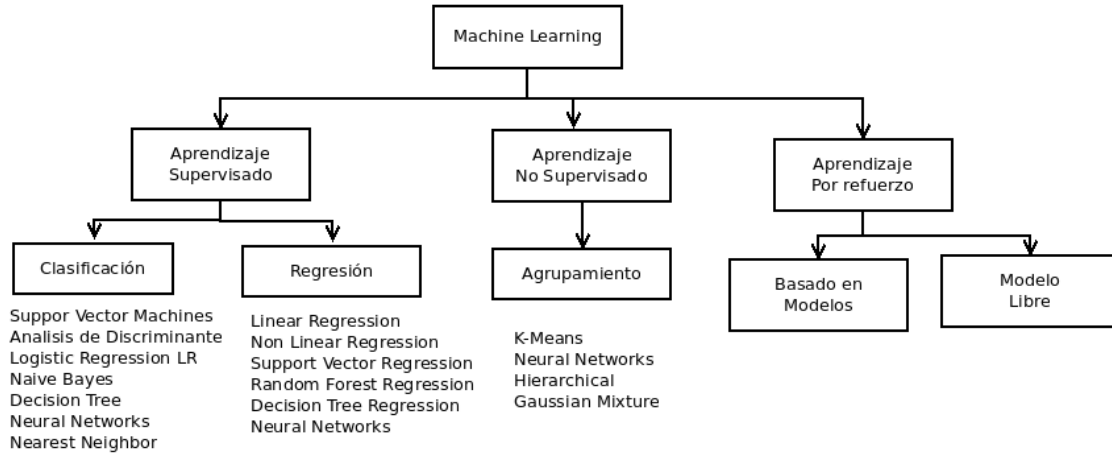


Figura 3.5: Red de Aeropuertos y pequeños Aeródromos de Chile.

Fuente: Adaptación, Justo-Silva et al. (2021)

Por su parte, el uso de ML supone una serie de ventajas entre ellas (DataFlair, 2021): Identificar tendencia y patrones en grandes bases de datos que manualmente tomaría mayor cantidad de tiempo; no requiere inferencia humana en el proceso. No necesita de reglas para su funcionamiento, puesto que el algoritmo es capaz de detectar relaciones de entradas y salidas independientemente; Permite manejar una gran cantidad de datos y dimensiones (variables); mejora continua del proceso de aprendizaje ante la incorporación de nuevos datos. Al mismo tiempo, algunas de sus desventajas son (DataFlair, 2021): la necesidad de adquirir una gran cantidad de datos en el proceso de formación de bases de datos para el aprendizaje; una correcta rectificación de los datos toma tiempo e identificar el error en modelos de "caja negra" es complejo.

En la Tabla 3.3, se hace una descripción detallada de algunos algoritmos de ML.

Tabla 3.3: Descripción de algoritmos de ML frecuentemente usados.

Algoritmo	Descripción	Ventajas	Desventaja	Mejor Uso
Logistic Regression	Se ajusta a un modelo que puede predecir la probabilidad de una respuesta binaria perteneciente a una clase u otra	-Debido a su simplicidad, la regresión logística se usa comúnmente como punto de partida para problemas de clasificación binaria.	-Imposibilidad de resolver directamente problemas no lineales.	Cuando los datos pueden estar separados por un solo límite lineal. Como base para evaluar métodos de clasificación más complejos.
Naive Bayes	Asume que la presencia de una característica particular en una clase no está relacionada con la presencia de ninguna otra característica. Clasifica nuevos datos en función de la probabilidad más alta de que pertenezcan a una clase en particular.	-Altamente escalable. -Fácil y rápido de implementar. -Buena alternativa para simplificar problemas de clasificación.	-Supone que todas las variables de entrada son independientes.	Para un pequeño conjunto de datos que contiene muchos parámetros. Cuando se necesita un clasificador de fácil interpretación. Cuando el modelo encuentra escenarios que no estaban en los datos de entrenamiento, como es el caso de muchas aplicaciones médicas y financieras.
SVM Regression	Consiste en realizar un mapeo de los datos de entrenamiento a un espacio de mayor dimensión a través de un mapeo no lineal; ajustando el error dentro de cierto umbral o hiperplanos.	-Útil para resolver problemas de altas dimensiones. -Continúa siendo efectivo en casos donde el número de dimensiones es mayor que el número de muestras. -Utiliza un subconjunto de puntos de entrenamiento o en la función de decisión ( llamados vectores de soporte), por lo que también es eficiente en la memoria.	-Si el número de características es mucho mayor que el número de muestras, el término de regularización es crucial. - Los SVM no proporcionan directamente estimaciones de probabilidad, estas se calculan utilizando una costosa validación cruzada de cinco veces.	Para datos de alta dimensión (donde habrá una gran cantidad de variables predictoras).
Decision Tree Regression	Predice las respuestas a los datos siguiendo las decisiones del árbol desde la raíz (principio) hasta un nodo hoja. Un árbol consta de condiciones de ramificación en las que el valor de un predictor se compara con un peso entrenado.	-Simple de entender e interpretar. Pueden ser visualizados. -Requiere poca preparación de datos. Otras técnicas a menudo requieren la normalización de datos, se deben crear variables ficticias y eliminar los valores en blanco. - manejar datos numéricos y categóricos. - Utiliza un modelo de caja blanca. La explicación de la condición se explica fácilmente por la lógica booleana.	- Los alumnos del árbol de decisión crean árboles sesgados si algunas clases dominan. Por lo tanto, se recomienda equilibrar el conjunto de datos antes de ajustarlo con el árbol de decisión. -Si el árbol es profundo, el número de muestras consideradas en cada decisión se vuelve pequeño. - los árboles de decisión es que son propensos a Overfitting.	Cuando un algoritmo que sea fácil de interpretar y rápido de ajustar es un requisito. Para minimizar el uso de memoria. Cuando no se requiere una alta precisión predictiva.

**Table 3.3 Descripción de algoritmos de ML frecuentemente usados (Continuación).**

Random Forest	<p>es una combinación de árboles de decisión, donde distintos árboles ven una porción distinta de los datos. Los resultados de cada árbol se promedian, teniendo una predicción que generaliza mejor.</p> <p>-Corren eficientemente en bases de datos grandes.                      -Tener un método eficaz para estimar datos perdidos y mantener la exactitud cuando una gran proporción de los datos está perdida</p>	<p>-Los bosques aleatorios pueden sufrir Overfitting con los datos cuando hay una gran cantidad de variables categóricas de alta cardinalidad.                      - Los bosques aleatorios, a diferencia de los árboles de decisión, no son fáciles de interpretar                      -Los bosques aleatorios también proporcionan modelos discretos para la predicción. Si la variable de respuesta es una variable continua, entonces solo hay n valores distintos que son posibles a través de la predicción</p> <p>Cuando los predictores son categóricos (discretos) o se comportan de forma no lineal. Cuando el tiempo no es una preocupación.</p>
K-Nearest Neighbor (kNN)	<p>Categoriza los objetos según las clases de sus vecinos más cercanos en el conjunto de datos. Las predicciones de KNN asumen que los objetos cercanos entre sí son similares.</p> <p>-Algoritmo simple para explicar, comprender e interpretar.                      -No paramétrico al no hacer suposición sobre la distribución funcional de los datos.</p>	<p>-KNN no es muy efectivo para datos que tienen clases sesgadas.                      - El algoritmo es sensible a todas las dimensiones (características) que considerara, incluso si alguna característica es totalmente irrelevante</p> <p>Cuando se requiere un algoritmo simple para establecer reglas de aprendizaje comparativas. Cuando el uso de la memoria y la velocidad de predicción del modelo entrenado es una preocupación menor.</p>
Artificial Neural Networks	<p>Comprende una serie de capas con neuronas interconectadas entre sí, mediante un valor denominado peso, que permite transmitir señales desde la capa de entrada a la de salida.</p> <p>-Capacidad para aprender modelos no lineales.                      -Capacidad para aprender modelos en tiempo real                      -Una RNA puede manejar cambios no importantes en la información de entrada, como señales con ruido u otros</p>	<p>-MLP con capas ocultas tienen una función de pérdida no convexa donde existe más de un mínimo local.                      -MLP requiere ajustar una cantidad de hiperparámetros, como la cantidad de neuronas, capas e iteraciones ocultas.                      -MLP es sensible al escalado de características.</p> <p>Para modelar sistemas altamente no lineales. Cuando los datos están disponibles de forma incremental y el objetivo es actualizar el modelo con regularidad. Cuando la interpretabilidad del modelo no es una preocupación clave.</p>

Fuente: Justo-Silva et al. (2021);Rebala et al. (2019);Inkoom et al. (2019);Piryonesi and El-Diraby (2017);Luo (2013);Diaz (2021);Bhavsar and Ganatra (2012).

Asimismo algunas características relacionadas con la rapidez de predicción, entrenamiento, uso de memoria y requerimientos de ajuste de hiperparámetros fueron analizadas cualitativamente por Justo-Silva et al. (2021), cuya adaptación se indica en la Tabla 3.4.

Tabla 3.4: Características de algunos algoritmos de ML.

Tipo de Algoritmo	Rapidez predicción	Rapidez entrenamiento	Uso de la Memoria	Requerimiento Hiperparámetros
DT	Rápido	Rápido	Bajo	Algunos
ANN	Moderado	Lento	Medio a Alto	Hartos
SVM (No Lineal)	Lento	Lento	Medio	Algunos
SVM (Lineal)	Rápido	Rápido	Bajo	Mínimos
Ensamblés (RFR)	Moderado	Lento	Variable	Algunos

Fuente: Adaptación Justo-Silva et al. (2021).

Ser capaz de generar modelos predictivos precisos y confiables requiere seguir una serie de pasos sistemáticos y que son transversal al problema aplicar. La Figura 3.6, representa el flujo de trabajo usual en problemas de ML.



Figura 3.6: Componentes a considerar en Modelos de Desempeño de Pavimentos.

Fuente: Elaboración propia.

Una breve descripción, sobre cada proceso indicado en la Figura 3.6, se indica a continuación:

- Definición del problema: Identificar la necesidad que requiere solución y estudiar problemas similares.
- Recolección de Datos: Recopilar datos relacionados con el fenómeno a estudiar. Emplear base de datos existe, etiquetando si es necesario o realizar nuevas mediciones.
- Preparación de Datos: Esta etapa requiere especial atención, puesto que los algoritmos requieren alimentarse de datos con información completa, escalada y transformada (variables categóricas) para su uso (Justo-Silva et al., 2021).

- Selección de Algoritmos y variables: los algoritmos a probar en un problema de ML queda a criterio del científico de datos al igual que las variables. No obstante, existen herramientas de optimización para seleccionar las variables como: métodos de filtro, métodos de envoltura y métodos integrados (May et al., 2011).
- Entrenamiento y validación: los algoritmos son entrenados a partir de un subconjunto del total de datos. Este subconjunto se escoge aleatoriamente y sirve para que el algoritmo aprenda los patrones de los datos y se verifique con el subconjunto de validación el rendimiento. Para asegurar la representatividad del proceso se utilizan técnicas de validación cruzada (en inglés, Cross validation), repitiendo el proceso de división en subconjuntos (entrenamiento-validación) repetidas veces. Entre las que destacan (Pedregosa et al., 2011): Cross-Validation con K-fold, Stratified K-Fold, Leave P Out, ShuffleSplit.
- Prueba y evaluación: En esta etapa se analiza si los algoritmos poseen la capacidad de generalización al realizar predicciones en un conjunto no visto en la etapa anterior. Además se realizan análisis cuantitativo y cualitativo de los resultados.

En esta sección no se revisará en detalla cada una de las etapas mencionadas puesto que serán descritas en el capítulo 5.

Por otro lado, a continuación se se explican algunos conceptos importantes en ML como: Overfitting (sobreajuste) y underfitting (subajuste) (Ver Figura 3.7)

En ML , se habla de overfitting o alta varianza, cuando los algoritmos aprenden bien en los datos de entrenamiento, pero no es capaz de generalizar en otros conjuntos de datos. El overfitting ocurre cuando los modelos son demasiado complejos en relación con el ruido y la cantidad de datos de entrenamiento. En tal caso se recomienda (Géron, 2019): incrementar la base de datos si ayuda a mejorar el desempeño de los modelos; simplificar el modelo con uno con menos parámetros, por ejemplo, usar un modelo lineal; reducir el ruido en los datos, por ejemplo, eliminando valores atípicos.

Por otro lado, ocurre Underfitting cuando el modelo es demasiado simple para aprender la complejidad de los datos. Por ende sus predicciones serán inexactas. Las principales soluciones para resolver este problema es (Géron, 2019): seleccionar un modelo más potente, con más parámetros; Mejorar la funciones del algoritmo, ajustar hiperparámetros; ajustar parámetro de regularización.




Figura 3.7: Ejemplo ilustrativo sobre overfitting y underfitting.  
Fuente: Recuperado de internet, Bagnato (2017).

Aunque existan bastantes tópicos a tocar en ML, en esta sección no se ahondará en detalles, pues para eso existe literatura especializada en el tema. Para facilitar la búsqueda de estos temas, a continuación se indican algunos libros, cursos y blog consultados en esta investigación:

- Aprendizaje Automático de la Universidad de Stanford (Curso).
- Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. (Géron, 2019).
- Deep Learning with Python. (Chollet, 2017).
- Machine learning mastery with Python: understand your data, create accurate models, and work projects end-to-end. (Brownlee, 2016).
- Machine Learning Mastery, Blog. (Brownlee, 2021).
- Ciencia de Datos, Estadística, Machine Learning y Programación. Blog. (Amat, 2021) .

## Modelos de Desempeño usando Machine Learning

En el ámbito de gestión de pavimentos de caminos y carreteras, en la última década se ha evidenciado el uso de herramientas de ML para la elaboración de modelos de desempeño de pavimentos, Ver figura 3.8. Probablemente su uso se ha vuelto cada vez más frecuente dada la gran cantidad de datos recopilados, el avance tecnológico y la capacidad computacional, junto a la facilidad de disponer de programas de distribución libre y códigos para su uso a través de la web.




Figura 3.8: Distribución de estudios de ML en modelos de desempeño de pavimento por intervalo de año.

Fuente: Elaboración propia a partir de Revisión bibliográfica de Díaz (2021).

A pesar de la masificación de ML en la predicción de la condición del pavimento de caminos y carreteras, su uso en la gestión de pavimentos aeroportuarios es limitado. Algunas razones que lo explican es que las bases de datos sobre pavimentos aeroportuarios no son públicas o en su defecto la información publicada es parcial, en contraste con múltiples estudios generados a partir de bases publicas como el Programa de investigación Long-Term Pavement Performance en caminos y carreteras (Fathi et al., 2019; Younos et al., 2020; Pirayonesi and El-Diraby, 2017; Ziari et al., 2016; Abdelaziz et al., 2020; Marcelino et al., 2021). Por otro lado, los principales software de gestión de pavimentos usados para esta tarea como PAVER, emplean regresiones para la predicción de la condición del pavimento no instaurando en el sistema otros algoritmos de ML que pudiesen incentivar su uso.

En la literatura se han hecho múltiples investigaciones utilizando ML para la generación de modelos de desempeño de pavimentos en carreteras, observando frecuentemente el uso de ANN para este fin (Alharbi, 2018; Roberts and Attoh-Okine, 1998; Tabatabaee et al., 2013; Thube, 2012; Yao et al., 2019; Wang et al., 2021; Domitrović et al., 2018; Choi et al., 2004; Hossain et al., 2020). No obstante, se ha observado que otros algoritmos de ML han sido utilizados con igual éxito para predecir la condición del pavimento como: SVR (Georgiou et al., 2018; Kargah-Ostadi, 2014; Ziari et al., 2016), RFR (Gong et al., 2018; Marcelino et al., 2021), DT (El-Diraby et al., 2017).

Asimismo, existen otras aplicaciones de ML en ingeniería de pavimentos, destacándose la realización de tareas de clasificación de deterioros y estados de la superficie (Augustaukas and Lipnickas, 2019; Abou Chacra and Zelek, 2018; Gao et al., 2018; Hoang and Nguyen, 2019), la estimación del módulo elástico para carpetas asfálticas (Bayrak and Ceylan, 2008; Gong et al., 2019; Gopalakrishnan and Papadopoulos, 2011; Khazanovich and Roesler, 1997; Leiva-Villacorta et al.,

2017), la asignación de estrategias de mantenimiento (Abdelrahim and George, 2000; Hafez et al., 2019; Huang et al., 2005), entre otros. En efecto, los múltiples usos de ML en la ingeniería de pavimentos, sumado los buenos resultados de precisión, capacidad de trabajar con problemas complejos de carácter no lineal, hacen presumir el buen rendimiento de estas técnicas en el desarrollo de modelos de desempeño de pavimentos.

Díaz (2021), hizo una revisión del estado del arte de técnicas de ML en el desarrollo de modelos de desempeño de pavimentos, formulando una herramienta para recomendar algoritmos de en base a los antecedentes del problema a modelar, esto es: información de datos históricos, forma de modelamiento, tipo de pavimento, variable de predicción, nivel de red o proyecto, proyección de la predicción. La Figura 3.9 , muestra un ejemplo de la herramienta desarrollada.




Figura 3.9: Ejemplo de resultado de Herramienta de visualización de aplicaciones de ML en modelos de desempeño de pavimentos.

Fuente: Díaz (2021).

Asimismo, Díaz (2021) proporciona una base de datos con modelos de pavimentos desarrollados con ML, que puede ser usada para estudiar los algoritmos más frecuentes y tipo de indicadores a predecir. AL respecto, la Figura 3.10 recoge las técnicas más usadas por indicador a predecir, de una base total de 101 documentos revisados.

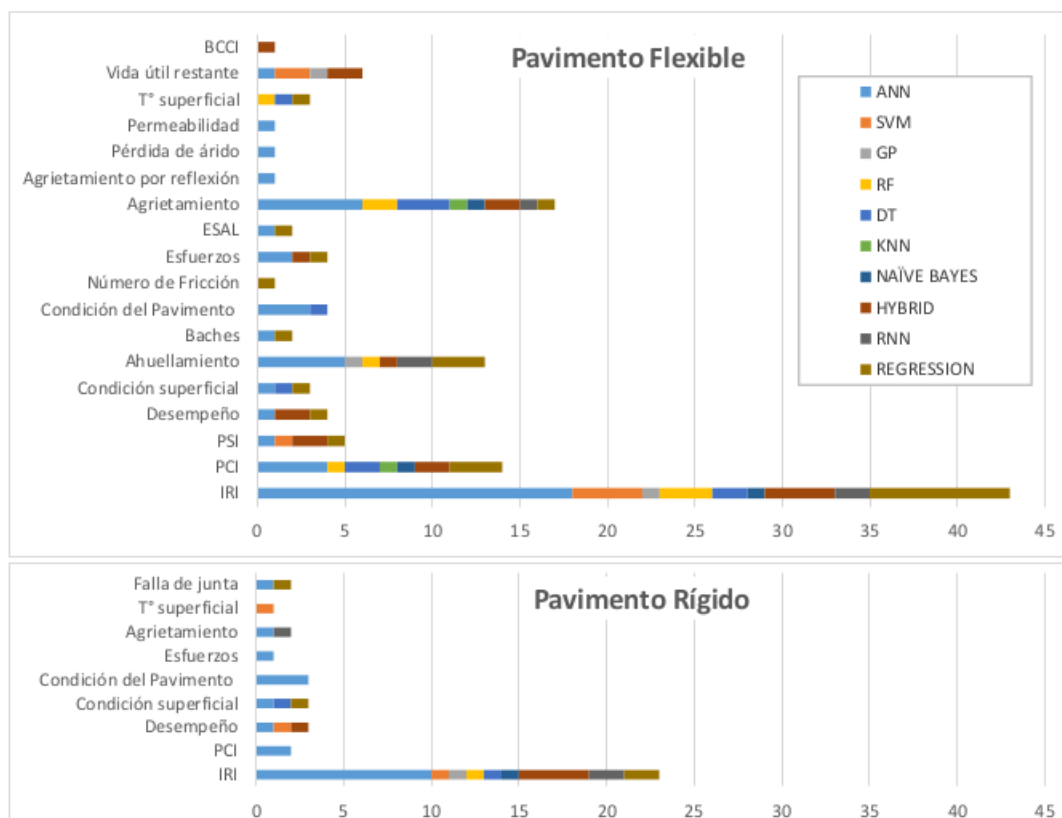


Figura 3.10: Herramientas de ML para cada variable de predicción, según tipo de pavimento. Fuente: Díaz (2021).

Respecto a la Figura 3.10, se destaca que los algoritmos más usados para predecir el indicador PCI en pavimentos flexible son ANN, RFR y DTR; mientras que, en pavimento rígidos sobresale ANN. Asimismo, cabe señalar que a pesar de que son investigaciones principalmente asociadas a pavimentos de caminos, el concepto tras el calculo del PCI es el mismo para pavimentos de aeropuertos.

La Tabla 3.5, recoge una lista de modelos que predicen el indicador PCI usando ML, identificando principalmente las variables usadas y el rendimiento alcanzado.

Tabla 3.5: Compendio de modelos de desempeño de pavimentos (PCI) usando ML.

Autor(es)	Variable Entrada	Descripción	Algoritmo	Desempeño
(Yan and Zhang, 2011)	IRI	Índice de rugosidad internacional.	SVM	$R^2 = 0.9726$
	SSI	índice de resistencia de la estructura del pavimento		
	SRI	índice de resistencia al deslizamiento del pavimento		
(Younos et al., 2020)	MAAT	temperatura media anual del aire ( $^{\circ}$ F),	ANN	$R^2 = 0.927$
	DESV MMAT	la desviación estándar de la temperatura media mensual del aire en un año determinado ( $^{\circ}$ F)		

Table 3.5 Compendio de modelos de desempeño de pavimentos (PCI) usando ML (Continuación).

Autor(es)	Variable Entrada	Descripción	Algoritmo	Desempeño
	WIND	viento la velocidad media anual del viento (mph)		
	WPI	índice de plasticidad ponderado		
	PRECIP	Precipitaciones		
	FI	el índice de congelación anual promedio ( ° F días)		
	TT	Tt el espesor total de las capas de pavimento (pulgadas)		
	CUM. MESALS	ESAL acumulados (millones)		
(Karballeezadeh et al., 2020)	FWD	Deflexión en los 7 sensores.	ANN	$R^2 = 14.33$
(Piryonesi and El-Diraby, 2019)	PAVEMENT TYPE	Tipo de pavimento (como lo define FHWA en LTPP)	Random forest	$Accuracy = 70.01 \pm 4.48$
	FREEZE INDEX YR	Índice de congelación calculado para el año (en días Celsius)	Decision tree I	$Accuracy = 81.05 \pm 5.97$
	MAX ANN TEMP AVG	Promedio de las temperaturas máximas diarias del aire por año		
	MIN ANN TEMP AVG	Promedio de las temperaturas mínimas diarias del aire por año		
	TOTAL ANN PRECIP	Precipitación total por año (en mm)		
	FUNC CLASS	Clase funcional de carretera (según lo definido por FHWA en LTPP)		
	FREEZE THAW YR	Número de ciclos de congelación-descongelación por año		
	OVERLAY THICKNESS	Espesor de la capa colocada en rehabilitación		
	AADT ALL VEHIC 2WAY	Tráfico diario medio anual		
	REMED TYPE	Tipo de última acción correctiva (según lo definido por FHWA en LTPP)		
	REMED YEARS	Número de años desde la última medida correctiva		
	CONSTRUCTION NO	Número de acciones correctivas realizadas		
	GBE	Equivalencia de base granular		
(Jalal et al., 2017)	AADT	Tráfico diario medio anual	ANN	$R^2 = 0.965$ , $RMSE = 19.61$
	Length	Largo Pavimento		
	Width	Ancho Pavimento		
	PAVEMENT TYPE	Tipo de pavimento		
	AGE	Edad desde construcción o conservación mayor		
(Kirbaş and Karaşahin, 2016)	AGE	Edad desde construcción o conservación mayor	ANN	$R^2 = 0.7456$
(Shahnazari et al., 2012)	TYPES OF DISTRESSES AND SEVERITY LEVELS	Diferentes tipos de angustias y niveles de gravedad	ANN	$R^2 = 0.9956$ , $RMSE = 1.74$ , $MAE = 065$
	$\Delta$ PCI	diferencia en el PCI entre el año actual y el anterior	ANN	$SSE' \leq 10.741$
	LOG AADT	Logaritmo del Tráfico diario medio anual		
	LOG ESAL	Logaritmo de Cargas equivalentes de un solo eje		
	AGE	Edad desde construcción o conservación mayor		
	SN	Numero Estructural		
	THICKNESS	Espesor de la losa		
(Mitchell, 2007)	AGE	Edad desde construcción o conservación mayor	ANN	$R^2 = 0.5184$ , $MSE = 123.74$
	THICKNESS	Espesor		
	APRON	Señala si el dato pertenece a la plataforma		
	TAXIWAY	Señala si el dato pertenece a la calle de rodaje		
	RUNWAY	Señala si el dato pertenece a la pista		

Table 3.5 Compendio de modelos de desempeño de pavimentos (PCI) usando ML (Continuación).

Autor(es)	Variable Entrada	Descripción	Algoritmo	Desempeño
(Barua et al., 2020)	AGE	Edad desde construcción o conservación mayor	ANN	$R^2 = 0.79$ (Pista) , $R^2 = 0.76$ (Calle Rodaje)
	DELTA T	tiempo transcurrido desde la última inspección	RF	$R^2 = 0.86$ (Pista) , $R^2 = 0.81$ (Calle Rodaje)
	PCI PREV	PCI de la última inspección		
	NUMBER OF FREEZE THAW CYCLES	Número de ciclos de congelación y descongelación de la inspección anterior		
	AMOUNT OF RAINFALL	cantidad de lluvia en mm desde la inspección anterior		
	KEEL LOCATION	se introduce para indicar si una sección está ubicada en el centro, es decir, la quilla ( tomando el valor 1), o el lado (tomando el valor 0) de una pista		
	NUMBER OF MINOR M&R ACTIONS	cuenta el número de actividades menores de M&R desde la última inspección.		
	OCURRENCE OF MAJOR M&R ACTION	si se ha llevado a cabo una acción importante desde la última inspección.		
	PCC	Portland Cement Concrete		
	APC	Asphalt Overlay on PCC		
AAC	Asphalt Overlay on Asphalt Concrete			

Fuente: Elaboración Propia.

De la Tabla 3.5, se verifica que los modelos de ML son capaces de capturar una gran variedad de variables o dimensiones de un problema a diferencia de los modelos clásicos de regresión hechos con tan solo una variable (edad del pavimento) y el indicador PCI. Por lo demás, se observa que entre las variables más usadas para predecir el indicador PCI, se encuentran los siguientes grupos de variables ordenados según su frecuencia, mayor a menor): información sobre la construcción del pavimento, condensado en la variable edad del pavimento, espesor y tipo de pavimento ; información del tránsito, representada bajo el tránsito diario medio anual y/o ejes equivalentes de un solo eje; variable asociada al clima, como temperatura, precipitación o ciclo de congelamientos; variables asociadas al desempeño del pavimento como indicadores estructurales, funcionales y estados previos de PCI; clasificación funcional del pavimento, uso y ubicación; variable asociada a la estructura; y en menor medida, variables asociadas al grado de mantenimiento de los pavimentos. No obstante, es importante señalar que la elección de las variables de estudio esta estrechamente relacionada a la capacidad de recolección de datos y a la naturaleza misma de ellos (variabilidad de estados, rangos y características de los pavimentos). Recomendándose al menos, tomar en consideración los grupos de variables señalados con anterioridad.

Entre otros estudios a destacar sobre ML y modelos de desempeño están los realizados por Bashar and Torres-Machi (2021) que evaluaron el desempeño global de SVR, RFR y ANN en la predicción de IRI por medio de análisis estadístico de 20 estudios. Proporcionando una orientación respecto a la arquitectura óptima y el tamaño mínimo de la muestra necesario para desarrollar estos modelos. Algunos de sus resultados son que RF es la técnica más precisa a nivel de los estudios revisados, Para ANN, una sola capa oculta con nodos igual a 0,3-2 veces el número de características

de entrada es suficiente para predecir y recomienda un tamaño de muestra mínimo igual a 50 veces el número de variables de entrada para modelar el deterioro del pavimento mediante ML. No obstante, se debe tener precaución al utilizar estos resultados dado que la muestra considerada en este estudio es reducida y las condiciones en que se desarrollaron los estudios puede no ser equivalentes.

Por otro lado, en el ámbito de aeropuertos el uso de estas técnicas es acotado. Uno de ellos es el estudio de Mitchell (2007) que desarrolló un modelo de desempeño para pavimentos de hormigón usando ANN que al comparar con regresión polinómicas encontró una mejora de la capacidad de predicción, con coeficiente de determinación ( $R^2$ ) de 0.518 para ANN y 0.368 para regresiones. Las variables que utilizó fueron la edad del pavimento, espesor y uso de la sección. Por otro lado, Barua et al. (2020) comparó el rendimiento de Gradient Boosting Machine (GBM) con otras técnicas como Linear regression , Quadratic regression , ANN, RF. Obteniendo mejores resultados de precisión con GBM para la predicción de PCI en pistas y calles de rodaje en el aeropuerto internacional de Chicago O'Hare.

# Capítulo 4

## Análisis y evaluación de la Base de Datos existente

Las bases de datos juegan un papel importante en los SGPA, sin esta información resulta complejo realizar tareas de planificación. Asimismo, el análisis y procesamiento de los datos se transforma en información útil para (Solminihaç et al., 2018): evaluar la condición de pavimentos; priorizar la inversión en mantenimiento en una red en el tiempo; simular los efectos de las decisiones de mantenimiento sobre la condición de la infraestructura; estimar los costos inducidos por las actividades de mantención; identificar impactos durante el ciclo de vida de los trabajos de mantenimiento.

En este capítulo se hará un análisis de la información disponible en la base de datos de la DAP, tomando en consideración su importancia para el desarrollo de una metodología para elaborar modelos de desempeño de pavimentos para la red primaria de aeropuertos. Algunos aspectos que son analizados son los tipos de mediciones realizadas (funcionales y/o estructurales), la frecuencia de muestreo y el análisis sobre el estado de los pavimentos en la Red Primaria de Aeropuertos, según los datos recogidos. Incluyendo además los niveles de precisión alcanzados en las predicciones hechas por consultores dentro de los proyectos de auscultación y evaluación de los pavimentos mediante licitaciones públicas presentadas por la DAP.

### 4.1 Antecedes de evaluación de Pavimento Aeroportuarios en Chile

Históricamente la DAP por medio de licitaciones y contratos de administración directa ha llevado acabo la auscultación de pavimentos. Destacándose el año 2014 con la auscultación total de la

red primaria de aeropuertos mediante el estudio denominado "Actualización de la información de infraestructura aeroportuaria de la Red Primaria". Cuyo objetivo era el levantamiento de y actualización de la información sobre la infraestructura aeroportuaria del país, incluyendo la evaluación funcional y estructural de los pavimentos.

Por lo demás, otras campañas han sido realizadas en el marco del programa de diagnósticos de pavimentos aeroportuarios, usando el software SIGES (Sistema de Gestión de Pavimentos Superficiales) y que solo han contemplado la evaluación de secciones específicas de algunos aeropuertos como : El Tepual, el 2017; Chacalluta y Balmaceda, el 2016; Carriel Sur, el 2018; entre otros. Asimismo, el uso de SIGES se ha ceñido principalmente a la transferencia automática de información de auscultación al equipo yuma.

Un resumen completo sobre las campañas de auscultación de Pavimentos de la Red Primaria en el periodo 2013-2021, basándose en el método PCI, se indican en la Tabla 4.1.

Tabla 4.1: Campañas de evaluación de Pavimentos Método PCI.

Aeropuerto/ Aerodrómo	Código OACI	Año									
		2013	2014	2015	2016	2017	2018	2019	2020	2021	
Arturo Merino Benítez	SCEL		x								
Diego Aracena	SCDA		x								x
Andrés Sabella	SCFA	x	x	x	x	x	x	x	x	x	x
El Tepual	SCTE	x		x		$x^*$					
Carriel Sur	SCIE	$x^*$	x				$x^*$				
Presidente Carlos Ibáñez del Campo	SCCI	$x^*$	x			$x^*$					
La Florida	SCSE	$x^*$	x			x		x			
El Loa	SCCF		x							$x^*$	x
Desierto de Atacama	SCAT		x				$x^*$	$x^*$	x		
Chacalluta	SCAR		x		$x^*$						x
Cañal Bajo / Carlos Hott Siebert	SCJO		x								
Balmaceda	SCBA		x		$x^*$						
Pichoy	SCVD	x	$x^*$		x						
Mataverí	SCIP		x								
Mocopulli	SCPQ						$x^*$		x		

Fuente: Elaboración Propia. Nota:  $x$ , para indicar auscultación completa del aeropuerto (lado aire);  $x^*$ , para indicar auscultación parcial de aeropuerto, solo algunas secciones fueron auscultadas.

En Tabla 4.1 se observa que en gran parte de los aeropuertos se han hecho 2 o 3 campañas de auscultación de PCI, destacándose el aeropuerto Andrés Sabella con campañas anuales de auscultación. Esto se explica a que el aeropuerto Andrés Sabella, antiguamente Cerro Moreno, es el único aeropuerto nacional concesionado, cuyo contrato de concesión contempla la ejecución, reparación, conservación y explotación de la obra pública fiscal señalada (MOP, 2011).

En cuanto a la información estructural, caracterización de la estructura y evaluación funcional

de los aeródromos y aeropuertos; cabe señalar que es levantada principalmente en la campaña de auscultación de pavimentos del 2014, por la empresa Ferrer & Asociados Ingenieros Consultores. Al respecto, un completo resumen de los datos recopilados se indican en la Tabla 4.2. Para mayor detalle sobre la información recopilada de los aeropuertos y aeródromos, ver Anexo D.

Tabla 4.2: Resumen completo de datos recopilados por área de estudio.

Área	Item	Actividades/Ensayo/Indice
Estudio de Mecánica de Suelos	Caracterización del Terreno	Exploración Geotécnicas de Suelos , Calicatas y plano de ubicación; composición del Subsuelo, Estratigrafía , situación de Napa Freática
	Propiedades de Diseño	Parámetros Geotécnicos, Coeficiente de Balasto; Capacidad de soporte CBR , Densidad y humedad óptimas
Estudio Estructural de Pavimentos	Estructura	Espesores de Testigos; Descripción Visual
	Características Estructurales de los Pavimentos	Análisis por Deflectometría: Módulo Elásticos de las capas; resistencia a la Flexotracción, Determinación de PCN
Estudio Funcional de Pavimentos	Evaluación Funcional de Pavimentos	Medición Coeficiente de Rozamiento de Pistas, Análisis y evaluación de Perfilometría: Regla, BBI; IRI, PI

Fuente: Elaboración Propia.

De igual forma el año 2019 por encargo de la DAP se licitaron nuevos contratos de auscultación de pavimentos denominado ” Diagnóstico Auscultación de Pavimentos Aeroportuarios de la Red Primaria Zona Norte”. Los cuales contemplan un análisis estructural y funcional del pavimento, junto una metodología de políticas y estrategias de mantenimiento. No obstante, es preciso señalar que en este trabajo solo se tuvo acceso a información de evaluación de PCI sobre las campañas mencionadas, ya que aún los contratos se encuentran en ejecución.

Con respecto a la frecuencia de inspección y actividades de diagnóstico del estado del pavimento la DGAC, encargada de normalizar las actividades aéreas, en la DAN 14 153 indica que los administradores de aeródromo deben incluir en su programa de mantenimiento las actividades de inspección señaladas en la Tabla 4.3. Es importante señalar que la frecuencia de inspección y diagnóstico debe ser indicada por la DGAC o en su defecto realizarse para fines de auditoría y/o cuando las reparaciones deban realizarse según necesidad.

Tabla 4.3: Frecuencias de mantenimiento e inspecciones.

Actividad	Responsable	Frecuencia**/ Tipo Mante***	Frecuencia Insp.	Modalidad de Inspección
Diagnóstico del estado del pavimento	Especialista	Semanal/ Preventivo	Fijada por la DGAC para cada Aeródromo ó aleatoria	Combinada
Verificación del PCN publicado (Comparación de los ACNs del tráfico realcon los PCNs)	Especialista	Anual/ Preventivo	Fijada por la DGAC para cada Aeródromo ó aleatoria	Instrumental combinado
Medición del rozamiento de las pistas pavimentadas. (En este caso Preventivo)	Especialista	Fijada por la DGAC para cada Aeródromo ó aleatoria	Fijada por la DGAC para cada Aeródromo ó aleatoria	Instrumental
Limpieza y eliminación de material pétreo de los pavimentos FOD	Especialista	Diaria/ Correctivo	Diaria	Visual

Fuente: Adaptación DAN 14 153 (Tabla 4-2-1).

Al mismo tiempo, la FAA, señala en la circular AC150/5380-7B (2014) que la frecuencia de las inspecciones detalladas por las encuestas de PCI puede extenderse hasta por tres años. Adquiriendo este criterio de muestreo los diferentes SGPA de Estados Unidos, debiéndose entre otras cosas a la Ley Pública 103-35 de Estados Unidos, que establece que para una agencia aeroportuaria sea elegible para financiamiento federal, debe contar un SGPA eficaz en lineamiento con la FAA (Tighe and Covalt, 2008).

En cuanto a las frecuencias de inspección para indicadores de fricción se sugieren los señalados en el Capítulo 2, Tabla 2.5 . Respecto al análisis de perfilometría que incluye el análisis de los índices: BBI, IRI, Straight Edge (Regla). La DAP adopta la medición de perfiles cada 2 m, abarcando los 30 m centrales en pistas y 20 m centrales en calles de rodajes; satisfaciendo los procedimientos de la circular AC 150/5380-9. Por su parte, los ensayos no destructivos se deben regir por la circular AC 150/5370-11, usando dichos criterio la DAP para la localización y ensayar los pavimentos. Lo anterior, de acuerdo a informes recogidos sobre la evaluación de los pavimentos.

Finalmente, respecto a la información estructural, funcional y el índice PCI disponibles se desprende que:

- Existe el esfuerzo constante por parte de la DAP de conocer el estado de los pavimentos. Destacando la recolección de una gran cantidad de datos asociados al PCI. No obstante, este indicador no ha sido recogido periódicamente en los mismo aeropuertos/aeródromos de la red

primaria a excepción del Aeropuerto Andrés Sabella. Por lo anterior, el Aeropuerto Andrés Sabella resulta ser un buen candidato para probar la metodología para elaborar modelos de desempeño que se pretende desarrollar.

- En vista de que los datos estructurales y funcionales no son recogidos con periodicidad. El uso de una variable asociado a un indicador funcional o estructural para elaborar un modelo de desempeño a nivel de proyecto es limitado, pensando que solo se tiene un dato (2014) y estos valores cambian en el tiempo. No obstante, si se pueden adquirir más valores en el tiempo y verificar si existen cambios sustanciales o no respecto a las variables señaladas, estos pudiesen incluirse en la modelación del desempeño de los pavimentos. Por lo demás, por un sentido de practica a pesar de que pueda existir cierta relación entre la capacidad estructural o aspectos relacionados con rugosidad de los pavimentos con el PCI, usar un estado anterior del PCI puede ser suficiente para predecir el siguiente estado tal como se ha visto en la estimación de otros indicadores que usan un estado anterior al índice que se quiere predecir (El-Hakim et al., 2013; Yang et al., 2006; Inkoom et al., 2019; Abdelaziz et al., 2020; Piryonesi and El-Diraby, 2017; Mazari and Rodriguez, 2016) .
- Se deben seguir haciendo esfuerzos y planes de actualización del estado de los pavimentos, lo que permitiría no solo poder planificar actividades de mantenimiento, sino también ampliar la base de datos para la elaboración de modelos de desempeño de pavimentos a nivel de red y proyecto.

## 4.2 Análisis Exploratorio de la Base de Datos

Para formular una metodología de modelos de desempeño de pavimentos, además de apoyarse en la literatura, se requiere conocer la naturaleza de la información encontrada, correspondiente a la materia prima de cualquier modelo matemático que se quiera desarrollar. Para ello, el análisis exploratorio de datos (EDA; Exploratory Data Analysis) permite conocer y comprender los datos empleando técnicas de resumen estadística y gráficos; fomentando y complementado la formulación de hipótesis estadísticas (Behrens, 1997).

A continuación, basándose en la metodología EDA, se hace un detallado análisis de los datos recolectados, enfocados principalmente en algunas variables explicativas del comportamiento del pavimento como indicador PCI que se quiere predecir, el tipo de pavimentos, la edad, espesores, entre otros. Cabe señalar que el tránsito aéreo y clima serán analizados separadamente, porque su uso en cualquier modelo de desempeño requiere un procesamiento extra como suponer de que forma será considerado.

## 4.2.1 Análisis Estadístico y Cualitativo de Base de Datos

Con el propósito de comprender la base de datos en la Tabla 4.4, se indica la cantidad de datos y secciones disponibles al considerar diferentes variables asociadas al desempeño del pavimento, uso, clima, tránsito, edad, tipo de pavimento entre otros.

Tabla 4.4: Cantidad de datos con información completa según variables consideradas.

Variables Consideradas										# Datos	# Secciones
PCI	Aeropuerto	Ubicación /Zona	Clima	Tránsito	Edad	Tipo Superficie	Espesor Capas	Área Sección	#E [Mpa] superficie		
x										1146	655
x	x									1146	655
x	x	x								1146	655
x	x	x	x							1146	655
x	x	x	x	x						1146	655
x	x	x	x	x	x					1114	642
x	x	x	x	x	x	x				1114	642
x	x	x	x	x	x	x	x			896	533
x	x	x	x	x	x	x	x	x		896	533
x	x	x	x	x	x	x	x	x	x	342	217

Fuente: Elaboración Propia.

Los resultados de la Tabla 4.4 muestran que la información estructural de la que se dispone es acotada respecto al resto de variables, reduciendo de 533 a 217 secciones con información completa sobre PCI, uso del pavimento, espesores y edad del pavimento. En consecuencia, su uso significa la disminución de datos disponibles para elaborar modelos de desempeño.

Por su parte, la Tabla 4.5 muestra los rangos globales y tipos de categorías relacionadas con los datos señalados. Para más detalle, ver Tabla D.1 en anexo D, que muestra los rangos típicos considerando el Aeropuerto y Rama, de los mismos. Al mismo tiempo, es importante señalar que la información del tránsito aéreo y de clima no se identifica en esta tabla, dado que serán examinados más adelante.

Tabla 4.5: Variables, Tipo, Rangos y/o Categoría de los Datos.

Variable	Tipo de Datos	Rango/Categoría
Aeropuerto	Categórico	Chacalluta, Diego Aracena, El Loa, Desierto de Atacama, Andrés Sabella, La Florida, Carriel Sur, Presidente Carlos Ibáñez del Campo, El Tepual, Balmaceda, Pichoy, Mataveri, Arturo Merino Benítez, Cañal Bajo / Carlos Hott Siebert, La Araucanía
Ubicación	Categórico	Pista, Plataforma, Rodaje Paralelo, Otros Rodajes, Margen y Zona a protección Chorro.
Zona	Categórico	Centro Pista, Borde Pista, Umbrales, Margen, Zona Protección a Chorro, Centro C. Rodaje Paralelo, Borde C. Rodaje Paralelo, Centro Otros Rodajes, Borde Otros Rodajes, Plataforma.
Superficie Pavimento	Categórico	Asfalto, Hormigón.
Área (m <sup>2</sup> )	Numérico	226-91200.
Nomenclatura Estructura Pavimento	Categórico	ACPC, AC, PCPC, PC, PCACPC, ACAC
Espesor	Numérico	4-46
Edad Pavimento	Numérico	0-60
Tipo de Pavimento	Categórico	Recapado, Convencional, Mixta
PCI	Numérico	25-100
Año Evaluación	Numérico	2013-2021
Sub Rasante E [Mpa]	Numérico	27-624
Sub-Base E [Mpa]	Numérico	80-4213
E Base [Mpa]	Numérico	111-3091
E Sup [Mpa]	Numérico	573-95418

Fuente: Elaboración Propia.

Para comprender como se distribuyen los datos en término de las variables recogidas, las Figura 4.1 y 4.2 indican la distribución de variables categóricas y numéricas respectivamente. Respecto a la variables numéricas la Tabla 4.6, muestra la estadística descriptiva de dichas variables.

Tabla 4.6: Estadística Descriptiva variables numéricas.

	PCI	Edad Pavimento	Espesor	Área [m <sup>2</sup> ]	E Sub Rasante [Mpa]	E Sub-Base [Mpa]	E Base [Mpa]	E Capa Sup [Mpa]
Cantidad	896	896	896	896	293	257	184	342
Promedio	87.4	16.2	17.9	10827.9	148.7	435.3	526.3	10575.1
Desviación Estandar	13.3	13.4	11.3	13283.2	124.4	399	640.7	13417.2
min	25	0	4	226	27	80	111	573
25%	81	6	10	2702.3	71	236	224	2207.5
50%	92	12	11	5719	105	317	280	4545
75%	98	22	30	11497	169	525.	453.5	15730
max	100	60	46	91200	624	4213	3091	95418

Fuente: Elaboración Propia.

Respecto a la Figura 4.1, se observa que la mayor cantidad de datos disponibles pertenecen al Aeropuerto Andrés Sabella, mientras que en su mayoría los datos corresponden a pavimentos convencionales de Asfalto. En tanto que, las secciones perteneciente a las pistas son las secciones más evaluada de la Red Primaria de Aeropuertos.

Por su parte la Figura 4.2 y Figura 4.4, muestra que la mayor cantidad de datos fueron registrados el año 2014. Con una edad en su mayoría bajo los 20 años. En cuanto a la distribución de PCI, se observa una concentración de los valores entre 70 y 100.




Figura 4.1: Distribución de variables cualitativas.  
Fuente: Elaboración propia.

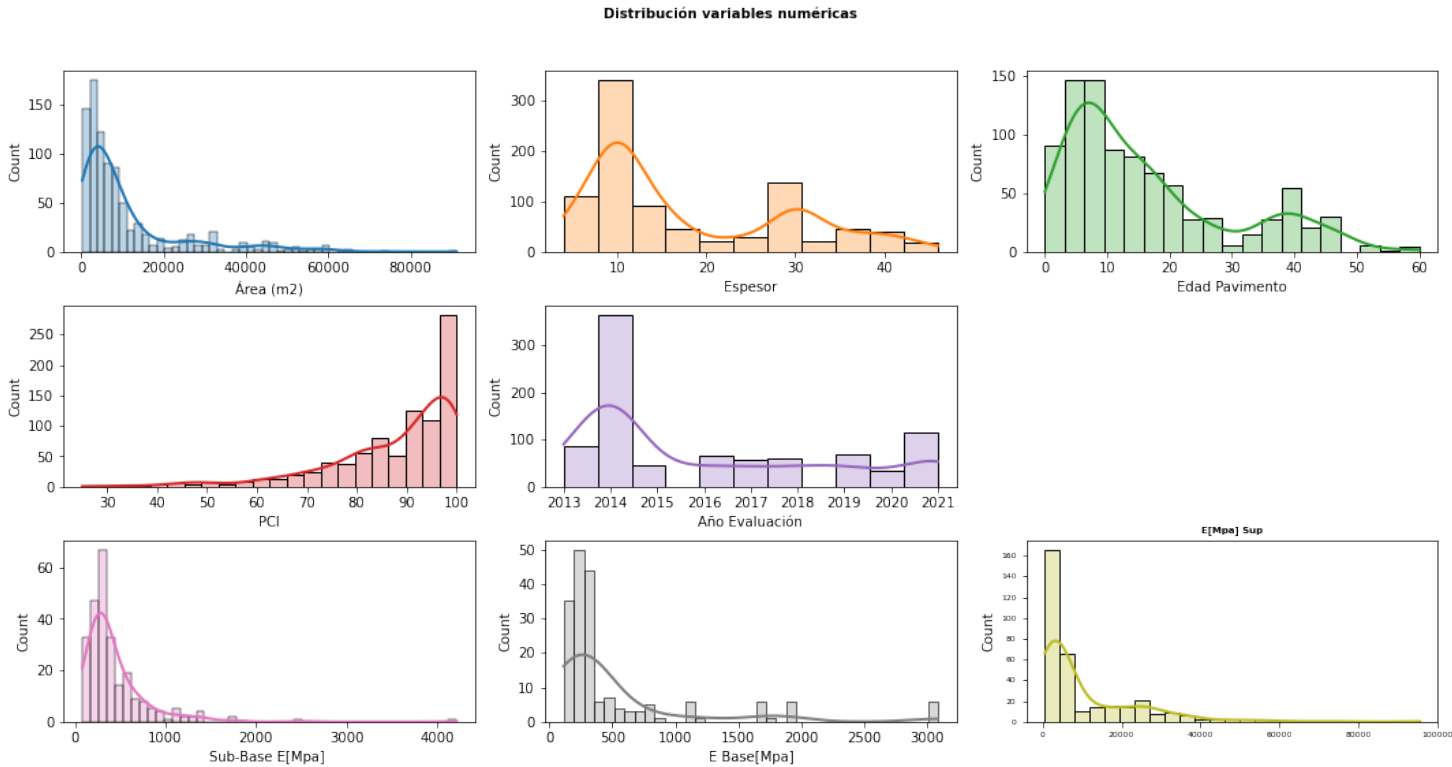


Figura 4.2: Distribución de variables numéricas.  
Fuente: Elaboración propia.

Con el objeto de encontrar relaciones entre las diferentes variables, la Figura 4.3 muestra los coeficientes de correlación entre las variables numéricas. Este análisis univariado permite identificar variables redundantes y además relaciones entre el indicador que quiere predecir (PCI) y el resto de variables.

En la Figura 4.3 se observa un alto grado de correlación entre los módulos de elasticidad de Base y SubBase ( $R^2 = 0.98$ ), Base y Subrasante ( $R^2 = 0.83$ ). Es importante recalcar que dada la baja cantidad de datos recogidos de estas variables, no se hace un análisis en profundidad respecto a las correlaciones halladas puesto que no se recomienda incorporarlas dentro de un modelo de desempeño, considerando además que son mediciones no periódicas en el SGPA.

Por otro lado, en la figura 4.3 no se observan fuertes correlaciones entre el PCI y otras variables ( $R^2 \leq 0.15$ ). Evidentemente, esto tiene relación con la gran dispersión de los datos, ver Figura 4.4. No obstante, si consideran grupos de secciones con similares características empleando el concepto de familia de pavimentos, estas correlaciones mejoran al disminuir la dispersión de los datos recogidos.




Figura 4.3: Matriz de correlación lineal (Pearson) entre variables numéricas.  
 Fuente: Elaboración propia.




Figura 4.4: Análisis de dispersión de la base de datos en función del indicador PCI y la edad del pavimento.

Fuente: Elaboración propia.

Para ejemplificar un análisis bajo el concepto de familia de pavimentos en los siguientes gráficos se muestran gráficos de dispersión de PCI en función de la Edad señalando las categorías asociadas, ver Figura 4.5. Por su parte la Tabla 4.7, muestra los coeficientes de correlación asociado a la figura señalada.

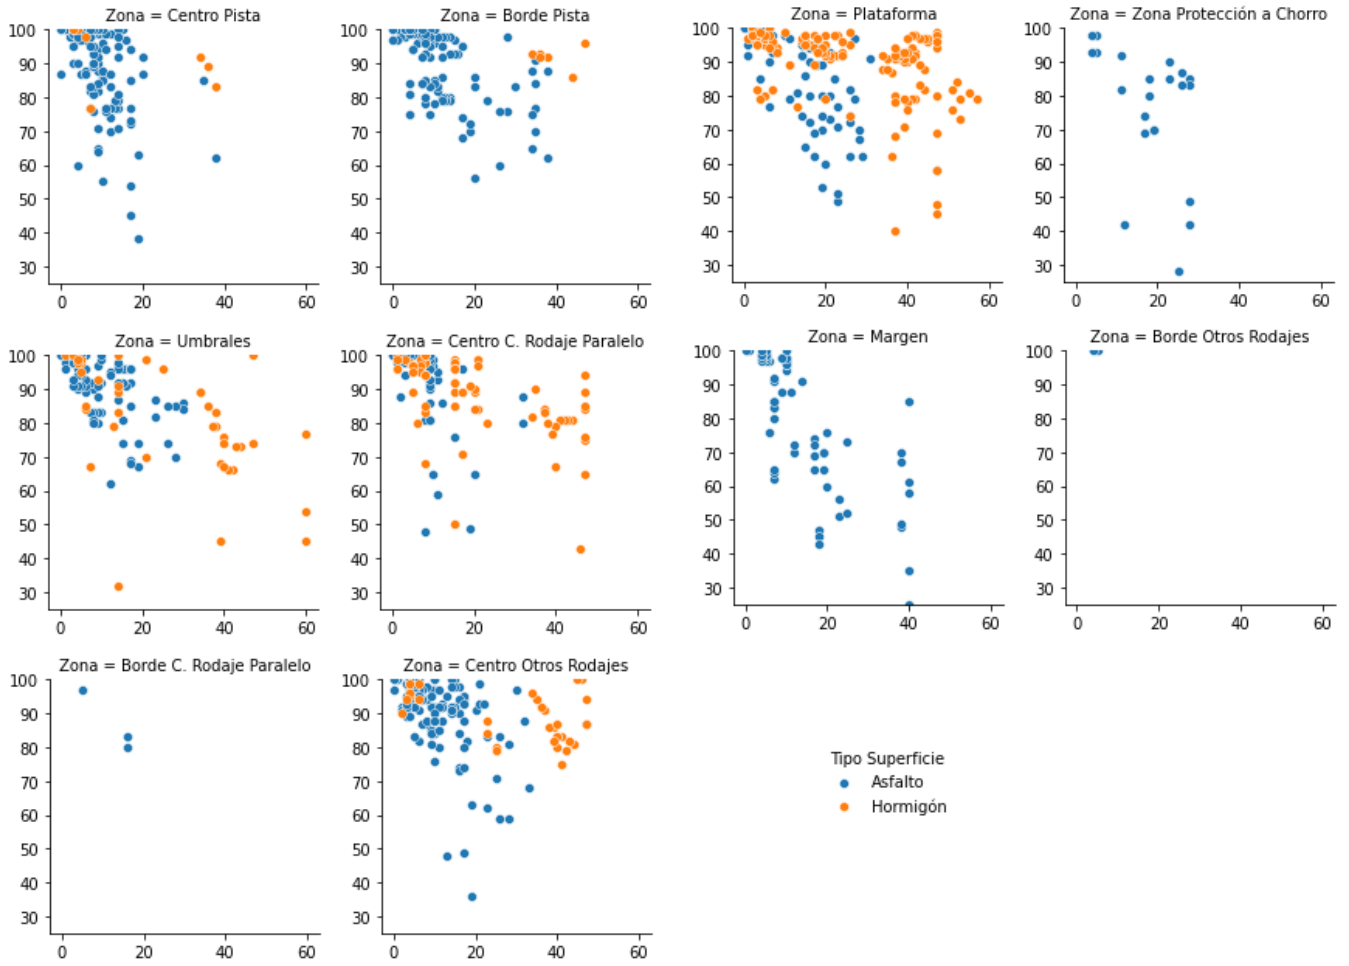


Figura 4.5: Distribución de PCI por rama y tipo de superficie.  
Fuente: Elaboración propia.

Tabla 4.7: Correlación entre PCI y Edad del pavimento por familia de pavimento.

<b>Familia Pavimento</b>			
<b>Zona</b>	<b>Tipo Superficie</b>	<b>#Datos</b>	<b><math>R^2</math></b>
Centro Pista	Asfalto	109	0.457
	Hormigón	7	0.412
Borde Pista	Asfalto	100	0.576
	Hormigón	6	0.071
Umbrales	Asfalto	73	0.523
	Hormigón	40	0.530
Plataforma	Asfalto	71	0.642
	Hormigón	127	0.422
Centro C. Rodaje Paralelo	Asfalto	47	0.446
	Hormigón	67	0.547
Borde C. Rodaje Paralelo	Asfalto	3	0.986
	Hormigón	0	-
Centro Otros Rodajes	Asfalto	122	0.485
	Hormigón	32	0.452
Borde Otros Rodajes	Asfalto	2	-
	Hormigón	0	-
Zona Protección a Chorro	Asfalto	22	0.444
	Hormigón	0	0
Margen	Asfalto	68	0.731
	Hormigón	-	-

Fuente: Elaboración propia.

Respecto a la Tabla 4.7, se observa mayor correlación lineal en las zonas de plataforma (superficie de asfalto) con coeficiente de determinación  $R^2 = 0.642$ , y la zona de margen (superficie de asfalto) con  $R^2 = 0.731$ . No obstante, las relaciones halladas son preliminares, puesto que el

proceso de deterioro del pavimento es evidentemente no lineal. Por su parte, este análisis sirve para agrupar los pavimentos con ciertas características que permitan hacer un análisis de grupo.

### Tránsito aéreo y clima

Probablemente, el tránsito aéreo sea una de las variables que tengan una influencia mayor en el proceso de deterioro de los pavimentos de aeropuertos. Por lo demás, es una de las variables más difícil de cuantificar, dado la gran variedad de líneas de desplazamiento de los trenes de aterrizaje de las aeronaves (ver Figura 4.6), consideraciones de peso y daño acumulado en los pavimentos que depende además de las características estructurales del pavimento y de un análisis de esfuerzo-deformación.

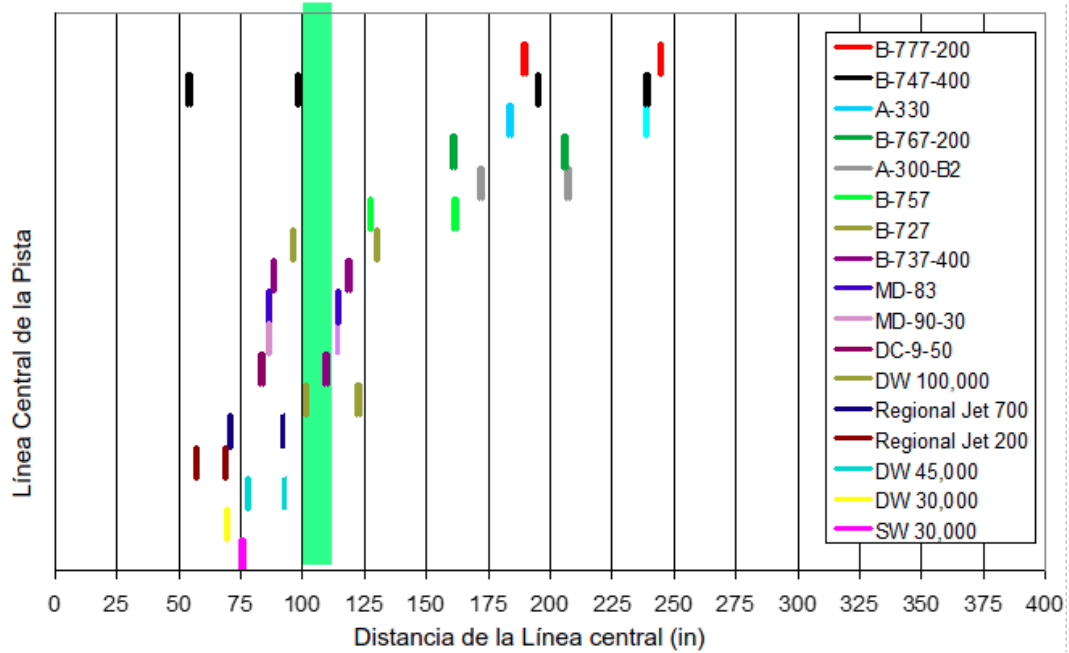


Figura 4.6: Distribución lateral del tránsito.  
Fuente: Eastern Region Aiport Conference , Rodney (2008).

Ahora bien, resulta importante hacer simplificaciones que ayuden a cuantificar la variabilidad del tránsito en los pavimentos sin entrar en análisis complejos que a la larga sean difíciles de medir y/o modelar en alguna metodología para elaborar estos modelos de desempeño de pavimentos. Por esta razón, preliminarmente se abordará esta variable en términos de operaciones realizadas en el período 2000-20019, con los datos de la red primaria de Aeropuertos, y en el Capítulo 6, se evaluarán diferentes métodos para cuantificar esta variable en un modelo de desempeño de pavimentos.

La Tabla 4.8 muestra la cantidad de operaciones de despegue por aeropuerto entre el 2000 y 2019. Asimismo la Figura 4.7, refleja lo indicado la Tabla 4.8. Cabe señalar, que la información señalada considera solo operaciones de despegue de aeronave con un peso máximo de despegue superior a 13 [Ton]. Los criterios anteriores se basan, en las circulares de diseño de la FAA. Respecto a la Figura 4.7 (a), se observa que el número de operaciones del aeropuerto Arturo Merino Benitez (SCEL) sobresale en comparación al resto de aeropuertos de la Red Primaria; esto se debe a que en el transporte aéreo chileno prevalece el modelo Hub-and-spoke, con centro neurálgico el aeropuerto Arturo Merino Benitez (Rojas, 2017). En tanto que en la Figura 4.7 (b), se observan ciertas similitudes en términos de la evolución de operaciones en cada aeropuerto.

Tabla 4.8: Operaciones de despegue Red Primaria, período 2000-2019.

Código OACI	Año																			
	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
SCAR	1747	1579	2262	2603	2655	2584	2133	1959	2016	2315	2542	3124	2886	2887	2736	2243	2453	2884	2920	3134
SCAT	0	0	0	0	0	1119	2196	2205	2030	2140	2537	3198	3352	3440	2749	1748	1763	2200	2166	2176
SCBA	842	886	964	1153	1176	1395	1639	1704	2009	1648	1624	1731	1903	1567	1541	1524	1877	1970	2195	2477
SCCF	1302	1272	1609	1626	2038	2471	3043	3336	3381	3171	4029	4179	4911	6550	5672	5005	4879	5579	6897	8027
SCCI	1581	1435	1415	1248	1533	2513	2627	2746	2628	2450	2563	2594	2807	2799	2848	2796	3352	3731	4488	4602
SCDA	4294	4264	4722	5732	5897	6386	6672	6438	5961	6066	6998	7812	7759	7753	7029	6283	5330	5445	5472	5655
SCEL	26231	26018	28660	29537	30473	33290	35081	41103	43554	42187	46784	53561	58638	61281	61971	62269	65438	72868	78230	81387
SCFA	5474	5162	5665	6001	6208	7636	9455	9152	7808	7604	9429	10042	9729	9846	10093	8873	7565	7361	7553	7720
SCIE	3182	2805	2931	4264	4497	4856	4598	4404	5238	4245	4241	4616	4872	5229	4727	3467	3366	4654	5022	5821
SCIP	182	195	194	184	250	269	367	369	478	488	507	444	538	514	519	513	510	556	612	694
SCJO	627	432	430	629	639	636	630	706	704	726	737	714	671	680	527	441	352	266	529	646
SCPQ	0	0	0	0	0	0	0	0	0	0	0	0	32	208	241	224	235	243	238	240
SCQP	0	0	0	0	0	0	0	0	0	0	0	0	0	0	900	2144	2318	2650	3160	3469
SCSE	1836	1534	1860	1729	1600	1632	1738	1440	1760	1873	2556	3642	3557	3465	3467	3090	2869	3232	3888	4530
SCTE	4933	4703	4872	5335	5885	7199	7159	6372	7180	6426	6190	6329	6549	7327	7006	6625	6767	6827	6312	6662
SCVD	460	464	618	678	681	678	691	784	995	453	760	810	785	901	860	659	732	759	924	1283

Fuente: Elaboración propia, a partir de datos de DGAC.




Figura 4.7: Operaciones anuales de despegue en aeropuertos de Red Primaria.

Fuente: Elaboración propia.

Para evaluar la similitud entre aeropuertos, se emplea un análisis aglomeramiento de tipo jerárquico (método ward), que se caracteriza por agrupar datos que posean la menor distancia euclidiana y que en etapas sucesivas conformarán un grupo. Este tipo de análisis ha sido con anterioridad, para segmentar tramos de carreteras con características similares de tránsito y en factores temporales de tránsito diarios, mensuales y anuales (Magaña-Cubillo et al., 2014; Vera et al., 2010; Papagiannakis et al., 2006). Por lo demás, cabe señalar que los aeropuertos de Arturo Merino Benitez es sacado del análisis por diferenciarse notoriamente del resto de aeropuertos; mientras que Mocopulli posee pocos datos para analizar.

La Figura 4.8 muestra el dendrograma creado, a partir de los datos analizados. Para seleccionar adecuadamente el número de cluster a crear, se emplea el método "average silhouette" que optimiza el número de cluster a seleccionar en base a la media de los coeficientes de silhouette. En este caso el número de cluster óptimos es 3, ver Figura 4.9.




Figura 4.8: Dendrograma que agrupa aeropuertos según operaciones de despegue.

Fuente: Elaboración propia.

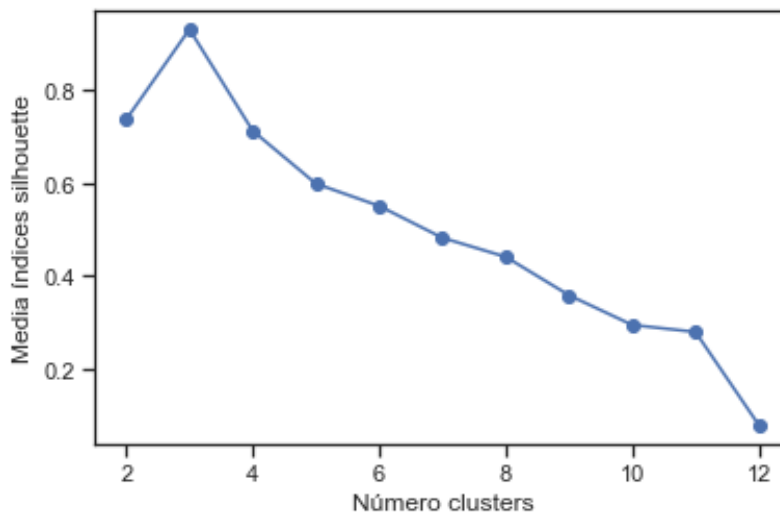


Figura 4.9: Evolución media de los índices de silhouette.  
Fuente: Elaboración propia.

En resumen, los límites identificados mediante agrupamiento aglomerativo para diferentes niveles de operación se señalan en la Tabla 4.9. Asimismo, otro tipo de consideraciones pueden realizarse para definir niveles asociados al tránsito aéreo como por ejemplo, considerar la cantidad de operación-carga para cuantificar además el peso de las aeronaves. No obstante, en este apartado no se incluye un análisis de este tipo, pues esta sección es meramente descriptiva y no pretende explicar el comportamiento de los pavimentos.

Tabla 4.9: Niveles de operación de despegue, por aeropuerto.

Nivel Operaciones	límite inferior	límite superior	Aeropuerto (OACI)
Bajo	0	890	SCAR, SCAT, SCBA, SCCF, SCCI, SCIE, SCSE
Medio	891	4885	SCVD, SCIP, SCJO, SCPQ
Medio Alto	4885	8938	SCFA, SCDA, SCTE
Alto	8938>	-	SCEL

Fuente: Elaboración Propia. Los rangos definidos, corresponden al promedio del grupo  $\pm 1.5$  desviaciones estándar.

En cuanto a la variable clima, es una de las variables más influyente en el desempeño de pavimentos (Osorio et al., 2015), afectando a la rigidez de los materiales y sufriendo expansión o contracción por efectos de gradientes de temperatura. Por lo demás, en la Guía Empírico Mecanicista de Diseño de Pavimentos AASHTO 2008 (MEPDG), las variables climáticas han sido tomadas en

cuenta en términos de temperatura, humedad relativa, velocidad del viento, exposición solar y precipitación. Respecto a esto último, (Qiao et al., 2013) concluyó que los factores de temperatura (aumento variación promedio anual), son los más influyentes en el diseño del pavimento.

Ahora bien, con el fin de proveer modelos prácticos y con información fácil de procesar, el análisis que se hará respecto al clima se basa en una clasificación por zona climática y no por un dato cuantitativo en específico. En tal caso, se emplea la clasificación climática de según sistema de Koppen del territorio nacional hecha por Rioseco and Tesser (2006), ver Figuras 4.10 y 4.11. Esta división climática considera 5 grupos principales (tropical, seco, templado, continental y polar), que a su vez se dividen en subgrupos para caracterizar el clima. Por lo demás, cabe señalar que esta clasificación climática a sido usada en estudios ligados a pavimentos, particularmente en la Zonificación SUPERPAVE para mezclas asfálticas de pavimentos en Chile (Delgadillo et al., 2017).

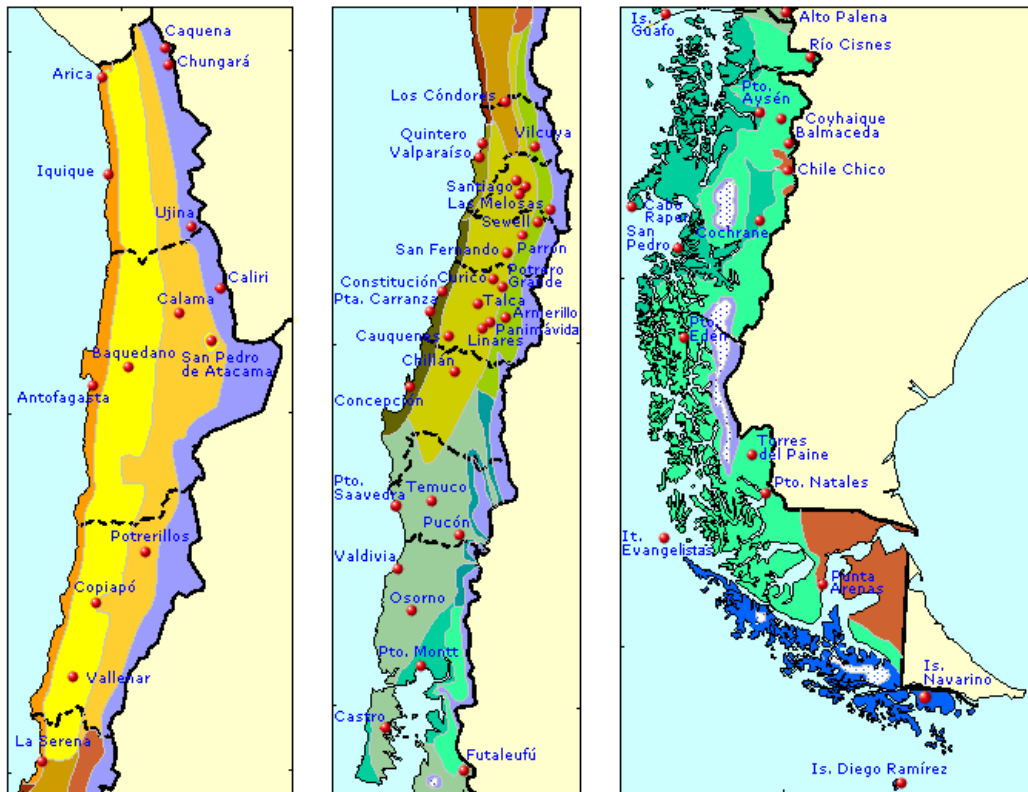


Figura 4.10: Clasificación climática del territorio nacional, según Koppen.

Fuente: (Rioseco and Tesser, 2006).

<b>CÁLIDO</b>	TROPICAL	<b>Afa</b>	Tropical lluvioso
	<b>SECOS</b>	ÁRIDOS	<b>BWk</b>
<b>BWk'</b>			Árido muy frío
<b>BWn</b>			Árido con nublados abundantes
SEMIÁRIDOS		<b>BSks</b>	Semiárido templado con lluvias invernales
		<b>BSk's</b>	Semiárido muy frío con lluvias invernales
		<b>BSn</b>	Semiárido con nublados abundantes
<b>TEMPLADOS</b>	LLUVIAS EN INVIERNO	<b>Csb</b>	Templado cálido con lluvias invernales
		<b>Csbn</b>	Templado cálido con lluvias invernales y gran nubosidad
		<b>Csbn's</b>	Templado cálido con lluvias invernales y gran humedad atmosférica
		<b>Csc</b>	Templado frío con lluvias invernales
	LLUVIAS TODO EL AÑO	<b>Cfb</b>	Templado lluvioso cálido sin estación seca
		<b>Cfbs</b>	Templado lluvioso cálido con influencia mediterránea
		<b>Cfc</b>	Templado lluvioso frío sin estación seca
		<b>Cfcs</b>	Templado lluvioso frío con influencia mediterránea
<b>FRÍOS</b>	TUNDRA	<b>ET</b>	Frío de tundra
		<b>ETi</b>	Frío de tundra isotérmico
		<b>ETH</b>	Frío de tundra por altura
	HIELO	<b>EF</b>	Frío de hielo polar
		<b>EFH</b>	Frío de hielo por altura

Figura 4.11: Simbología clasificación climática de Koppen.

Fuente: (Rioseco and Tesser, 2006)

De acuerdo a lo anterior, la clasificación climática por aeropuerto se recoge en la Tabla 4.10. Distinguiendo al menos 5 zonas climáticas : Seco, árido; Cálido, Tropical; Templado, con lluvias en invierno; Templado con lluvias too el año; y por último, seco semiarido con lluvias invernales.

Tabla 4.10: Clasificación climática de Koppen por aeropuerto.

OACI Informante	Nomeclatura Koppen	Descripción	Características Térmicas	Características Pluviométricas	Zona Climática
SCAR SCDA SCFA SCSE	Bwn	Árido con nublados Abundantes	Presencia frecuente de nieblas		Seco-Árido
SCCF SCAT	BW'k	Árido muy frío	la temperatura media anual y media mensual del mes más cálido es inferior a 18°C.		
SCIP	Afa	Tropical LLuvioso	Temperatura media mensual Superior a 18°C.	La Precipitación del mes más seco es mayor a 60 mm	Cálido-Tropical
SCEL	Csb	Templado cálido con lluvias invernales	La temperatura media del mes más cálido es inferior a los 22°C y, al menos, cuatro meses, con temperaturas medias que superan los 10°C.	La precipitación del mes más seco en verano es inferior a un tercio de la del mes	Templado-LLuvias Invierno
SCIE	Csbn's	Templado cálido con lluvias invernales y gran humedad atmosférica		Más lluvioso de invierno.	Templado-LLuvias Invierno
SCQP SCVD SCJO SCPQ	Cfb	templado lluvioso cálido sin estación seca	La temperatura media del mes más cálido es inferior a los 22°C y, al menos, cuatro meses, con temperaturas medias que superan los 10°C.	Carece de una estación seca, El monto de precipitación del mes más lluvioso está comprendido entre tres y diez veces la precipitación del mes más seco.	
SCTE	Cfbs	Templado lluvioso cálido con influencia mediterranea	La temperatura media del mes más cálido es inferior a los 22°C y, al menos, cuatro meses, con temperaturas medias que superan los 10°C.	Carece de una estación seca, El monto de precipitación del mes más lluvioso está comprendido entre tres y diez veces la precipitación del mes más seco. La precipitación del mes más seco en verano es inferior a un tercio de la del mes más lluvioso de invierno.	Templado-LLuvias todo el año
SCBA	Cfc	Templado lluvioso frío sin estación seca	La temperatura media del mes más frío es superior a -38°C y el mes más cálido es inferior a 22°C, y menos de cuatro meses tienen una temperatura media que supera los 10°C.		
SCCI	Bsk's	semiárido muy frío con lluvias invernales	La temperatura media anual y media mensual del mes más cálido es inferior a 18°C	La precipitación de invierno (HS: de abril a septiembre, HN : de octubre a marzo) en centímetros es igual o menor a dos veces la temperatura media anual en grados Celsius.	Seco-Semiárido (con lluvia invernales)

Fuente: Elaboración Propia.

Finalmente, a partir de las clasificaciones de tránsito, clima, rama y tipo de pavimento; se puede construir una matriz factorial que identifica la cantidad de datos con tales características en la Tabla 4.11. Sin embargo, como se puede apreciar en la tabla mencionada, los cantidad de datos disponible es baja, y por ejemplo para el caso que se disponen 70 datos en plataforma (SCEL),

estos corresponden a mediciones de un solo año (2014), no sirviendo para modelar.

Tabla 4.11: Distribución de datos según tránsito, clima y superficie del pavimento.

Transito	Clima	Superficie Asfalto			Superficie Hormigón			
		OACI Informante	Centro Pista	Centro Calle Rodaje	Plataforma	Centro Pista	Centro Calle Rodaje	Plataforma
Bajo	Seco-Árido	SCAR,SCAT,SCCF,SCSE	16	11	45			15
	Templado-Lluvias todo el Año	SCBA	4		6			2
	Seco-Semiárido (con lluvias Invernales)	SCCI	15		2	2	1	4
	Templado Lluvias Invierno	SCIE	2	7	1			3
Medio	Templado-Lluvias todo el Año	SCVD,SCJO,SCPQ	11		6			8
	Calido Tropical	SCIP	4		2			
Medio Alto	Seco-Árido	SCFA,SCDA	48	20	9	2	11	73
	Templado-Lluvias todo el Año	SCTE				3	4	20
Alto	Templado Lluvias Invierno	SCEL	9	9			51	70

Fuente: Elaboración Propia.

## 4.2.2 Estado de la Red Primaria de Aeropuertos

Para contribuir al análisis de los datos, en este apartado se revisa el estado de la Red Primaria de aeropuertos de Chile en función del Indicador PCI.

Al respecto, la figura 4.12 muestra la distribución de PCI por rama en cada aeropuerto, ponderando el valor de PCI por el área de las secciones que la componen, según la ecuación 4.1.

$$PCI_{PA} = \frac{\sum PCI_{ri} \cdot A_{ri}}{\sum A_{ri}} \quad (4.1)$$

Donde:

$PCI_{PA}$ = PCI Ponderado en las áreas de la secciones que componen la Rama del aeropuerto analizado.

$PCI_{ri}$ = PCI de la Sección i.

$A_{ri}$ = Área de la sección i.

La Figura 4.12 muestra que no existe una periodicidad en el registro de datos de PCI por aeropuerto y por rama. Al mismo tiempo, de acuerdo a la Norma ASTM D 5340, Figura 4.13, la clasificación cualitativa de los pavimentos de la Red Primaria para pista es entre Excelente y Bueno

, salvo zonas de Margen con nivel Pobre. Por su parte, la zona de Rodaje en Paralelo, se encuentra entre Excelente y Regular, con una tendencia a estar en condición Muy Bueno y Bueno. Al mismo tiempo, la Plataforma se encuentra estado Excelente con unas pocas secciones en estado Regular. Finalmente, el análisis del estado del pavimento ayuda a realizar actividades de mantenimiento planificadas en aquellas zonas con PCI más disminuido y mantener la condición en zonas con PCI en mejor estado, evitando realizar actividades de mantenimiento tardía que signifiquen un mayor costo.

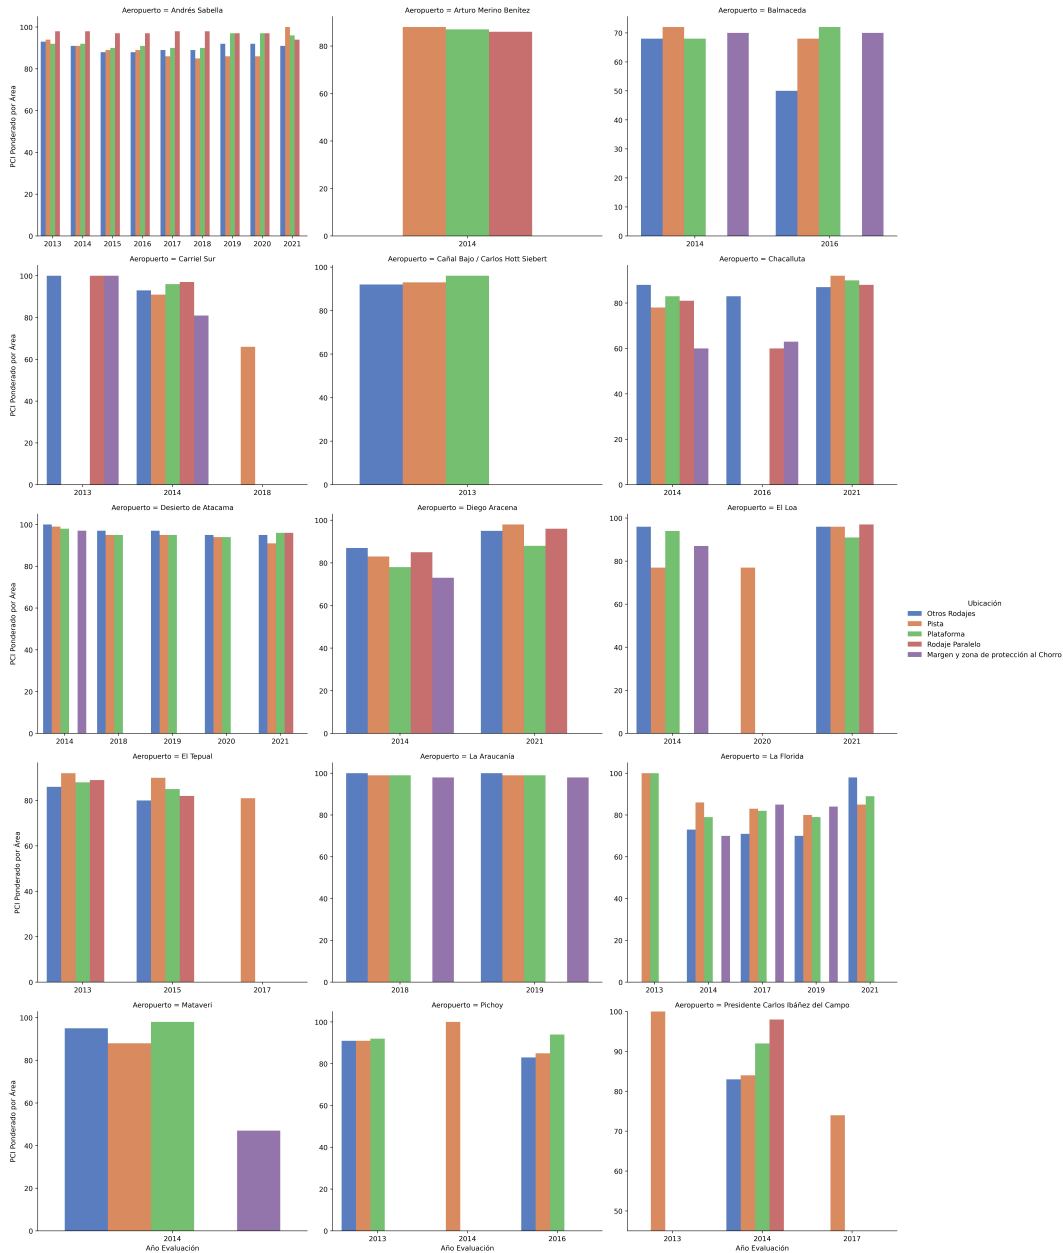


Figura 4.12: Estado Red Primaria de aeropuerto en base a indicador PCI.  
Fuente: Elaboración propia.




Figura 4.13: Escala de clasificación del estado del pavimento en PCI.

Fuente: ASTM D 5340

En tanto, que la Tabla 4.12 muestra las variaciones cualitativas del estado del pavimentos en términos de PCI.

Tabla 4.12: Evolución cualitativa sobre el estado del pavimento por aeropuerto.

OACI Informante	Pista	Plataforma	Rodaje Paralelo	Otros Rodajes	Margen	Periodo
SCFA	Excelente-Muy Bueno	Excelente-Excelente	Excelente-Excelente	Excelente-Excelente	-	2014-2021
SCEL	Excelente	Excelente	Muy Bueno	-	-	2014
SCBA	Muy Bueno-Bueno	Bueno-Muy Bueno	-	Bueno-Regular	Bueno-Bueno	2014-2016
SCJO	Excelente	Excelente	-	Excelente	-	2013
SCIE	Excelente-Bueno**	Excelente*	Excelente-Excelente	Excelente-Excelente	Excelente-Muy Bueno	2013-2014; *: 2014; **: 2014-2018
SCAR	Muy Bueno-Excelente**	Muy Bueno-Excelente**	Muy Bueno-Bueno-Excelente*	Excelente-Muy Bueno-Excelente*	Bueno-Bueno	2014-2016; *: 2014-2016-2021; **: 2014-2021
SCAT	Excelente-Excelente	Excelente-Excelente	Excelente**	Excelente-Excelente	Excelente*	2014-2021; *: 2014; **: 2021
SCDA	Muy Bueno-Excelente	Muy Bueno-Excelente	Muy Bueno-Excelente	Excelente-Excelente	Muy Bueno*	2014-2021; *: 2014
SCCF	Muy Bueno-Excelente	Excelente-Excelente	Excelente**	Excelente-Excelente	Excelente*	2014-2021; *: 2014; **: 2021
SCTE	Excelente-Muy Bueno*	Excelente-Muy Bueno	Excelente-Muy Bueno	Muy Bueno-Muy Bueno	-	2013-2015; *: 2013-2017
SCQP	Excelente-Excelente	Excelente-Excelente	-	Excelente-Excelente	Excelente-Excelente	2018-2019
SCSE	Excelente-Muy Bueno	Excelente-Muy Bueno	-	Muy Bueno-Bueno-Excelente	Bueno-Muy Bueno	2013-2021; *: 2014-2021; **: 2014-2019
SCIP	Excelente	Excelente	-	Excelente	Regular	2014
SCVD	Excelente-Muy Bueno	Excelente-Excelente	-	Excelente-Muy Bueno	-	2013-2016
SCCI	Excelente-Muy Bueno	Excelente*	Excelente*	Muy Bueno*	-	2013-2017; *: 2014

Fuente: Elaboración Propia.

### 4.2.3 Análisis de Predicciones de PCI años anteriores

En esta parte, se hace un análisis sobre las predicciones hechas por consultores dentro de los proyectos de auscultación de pavimentos de la DAP de la Red Primaria de Aeropuertos. Analizando los valores proyectados versus los medidos en campañas de auscultación posterior a la fecha de

predicción.

Por su parte es preciso señalar que aún cuando las mayorías de las predicciones fueron hechas por empresa Ferrer & Asociados Ingenieros Consultores usando PAVER. No existe un respaldo sobre el proceso para obtener dichos resultados, por ende no puede replicarse dicho experimento y a la larga significa usar datos a ciegas en los procesos de toma de decisión. No obstante a lo anterior, las proyecciones hechas se consideran válidas en el análisis.

La Figura 4.14, muestra la correlación existente entre los datos medidos y proyectados de PCI. Obteniendo un coeficiente de determinación  $R^2 = 0.66$  para las variables señaladas. Observando además, el ajuste de los entorno al eje de  $45^\circ$ .




Figura 4.14: Correlación existente entre valores medidos y predichos de PCI.

Fuente: Elaboración propia.

Un análisis de residuos fue hecho, ver Figura 4.15, observando que las proyecciones hechas tienden a sobre estimar el valor de PCI, alcanzando errores incluso sobre 20 PCI. Por su parte, el error absoluto medio (MAE) fue calculado obteniendo un error de 5.73 PCI.

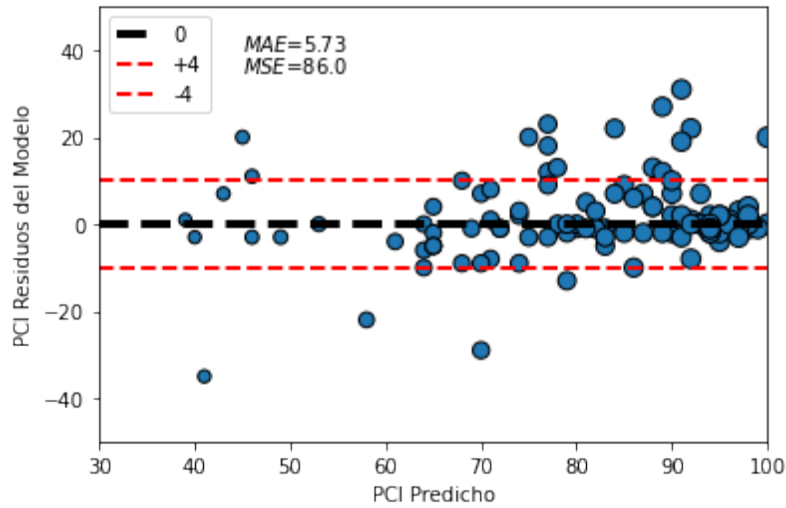


Figura 4.15: Análisis de residuos para predicciones de PCI.  
Fuente: Elaboración propia.

Respecto a la concentración de errores por rama, la Figura 4.16 muestra como se distribuyen los errores en un gráfico de cajas. Observando en pistas, que la media se sitúa cercana a 5 y con el 75% de los datos bajo 11 PCI, siendo la rama en la que se observa un error mayor. Asimismo, en calles de rodaje paralelo se observa asimetría positiva, observando que los errores se concentran principalmente en la parte inferior de la distribución.

Finalmente se recomienda hacer esfuerzos para elaborar modelos de desempeño de pavimentos integrando información local de la red de aeropuertos. Incluyendo análisis de bases de datos robustas de la realidad local, con el fin de disminuir los errores encontrados en las predicciones revisadas.




Figura 4.16: Distribución de Error Absoluto por rama.  
 Fuente: Elaboración propia.

## Capítulo 5

# Propuesta Metodológica para elaboración de Modelos de Desempeño de Pavimentos de Aeropuertos

Este capítulo se ordena partiendo con un diagrama de flujo que representa visualmente los procesos para elaborar modelos de desempeño usando ML, objetivo general de esta tesis. Asimismo, la explicación de los procesos es revisada en detalle en las secciones posteriores.

Además, la metodología propuesta recoge los resultados de investigaciones pasadas de Marcelino et al. (2021) y Justo-Silva et al. (2021) que por separado elaboraron marcos teóricos para la elaboración de modelos de desempeño de pavimentos. Marcelino et al. (2021), formularon una metodología pensada en el trabajo de variables desde un enfoque de series de tiempo, basándose en investigaciones pasadas de Bontempi et al. (2012); aplicando dicha propuesta en la predicción del indicador de rugosidad IRI. Para ello empleó diferentes conjuntos de variables, asociadas al tránsito, clima, estructura e indicador de desempeño en tiempos anteriores o rezagados; encontrando que las predicciones a corto plazo (5 años) poseían una precisión mayor al largo plazo (10 años), encontrando que los modelos con una mayor cantidad de datos anteriores sobre la variable a predecir no necesariamente son los más precisos. Mientras que Justo-Silva et al. (2021), hace un revisión detallada sobre el funcionamiento de ML y algunos algoritmos con frecuencia usados en esta área.

Finalmente en la siguiente sección se define el proceso propuesto para elaborar modelos de desempeño de pavimentos en base a todos los antecedentes recopilados en los capítulos anteriores.

## 5.1 Metodología Propuesta

Aunque la aplicación misma de un algoritmo de ML implica una serie de pasos definidos y que en general es transversal al problema que se quiere solucionar, ver Figura 3.6; se debe tener en cuenta la experiencia y la intuición para elaborar en primer lugar un plan de recolección de información, optimización de hiperparámetros y selección de variables, seguido de la selección de algoritmos y posterior análisis de resultados. En efecto, en aeropuertos se ha de tener en cuenta las variables asociadas al deterioro progresivo de los pavimentos como los materiales, el tránsito, el clima, su uso y la información de la estructura; además del tipo de análisis a realizar, es decir, análisis a nivel de proyecto o red; la cantidad de datos disponibles; la experiencia ingenieril para el posterior análisis de resultados; y finalmente un software o código para implementar el proceso de predicción de la condición de los pavimentos. La Figura 5.1, que recoge algunos componentes claves a considerar en el desarrollo de modelos de desempeño en aeropuertos.

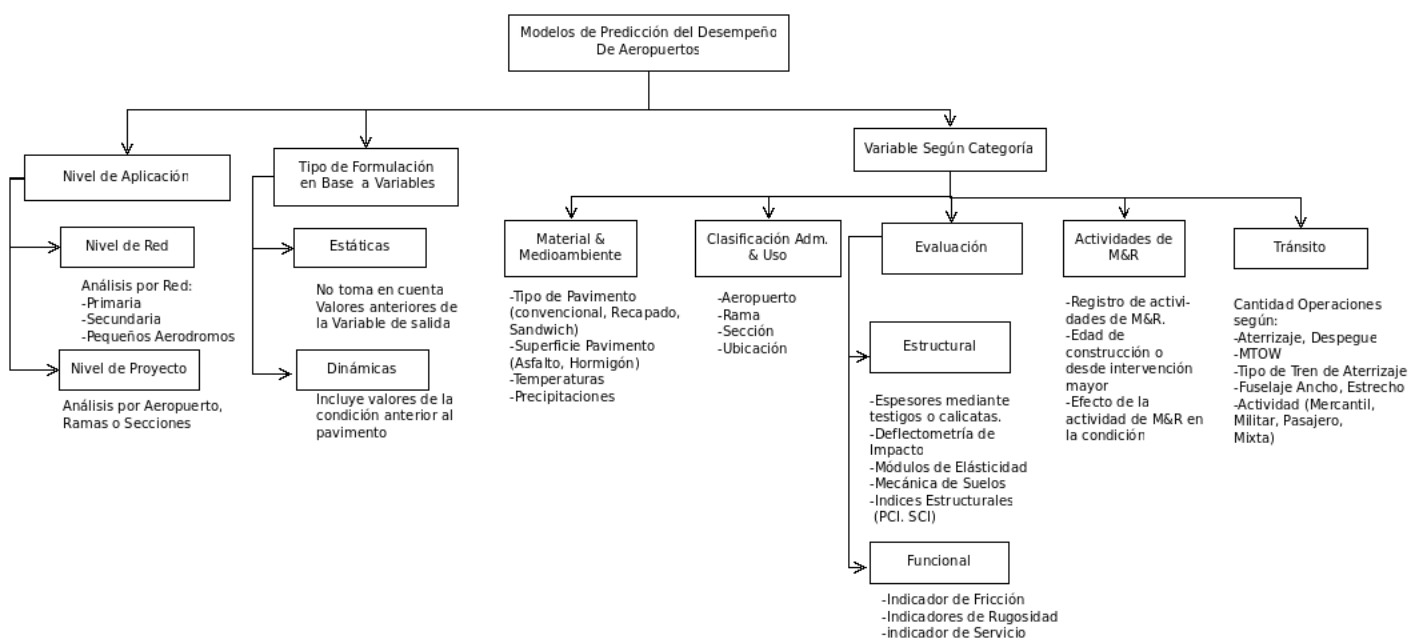


Figura 5.1: Componentes a considerar en Modelos de Desempeño de Pavimentos.  
Fuente: Elaboración propia.

### 5.1.1 Diagrama Metodológico

Con el fin de facilitar el proceso de elaboración de modelos de desempeño de pavimentos aeroportuarios usando técnicas de ML, esta metodología contempla 5 etapas o módulos de trabajo que se señalan en la Figura 5.2 y que serán descritas a continuación.

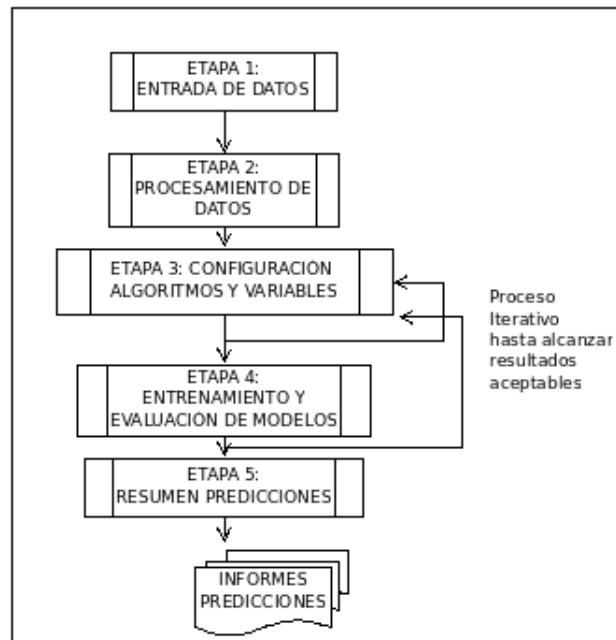


Figura 5.2: Esquema general propuesto para elaborar modelos de desempeño de pavimentos de aeropuertos con ML.

Fuente: Elaboración Propia.

### Etapa 1: Entrada de datos

En esta primera etapa, ver Figura 5.3, se detalla información de entrada del modelo como: Un nombre para el modelo, útil para guardar configuraciones y abrir posteriormente; indicación si corresponde a un modelo de red o proyecto, para tabular o agrupar datos según categorías señaladas; algoritmos de ML a usar; tiempo de predicción, señala el período a predecir en términos de la edad del pavimento; tipo de formulación, indica si las variables de entrada del modelo deberán ser ordenadas temporalmente o no; base e datos, registro individual de diferentes datos asociados a información administrativa (ubicación y uso), información climática, información previa de actividades de M&R, datos sobre la estructura del pavimento, tránsito, entre otros.

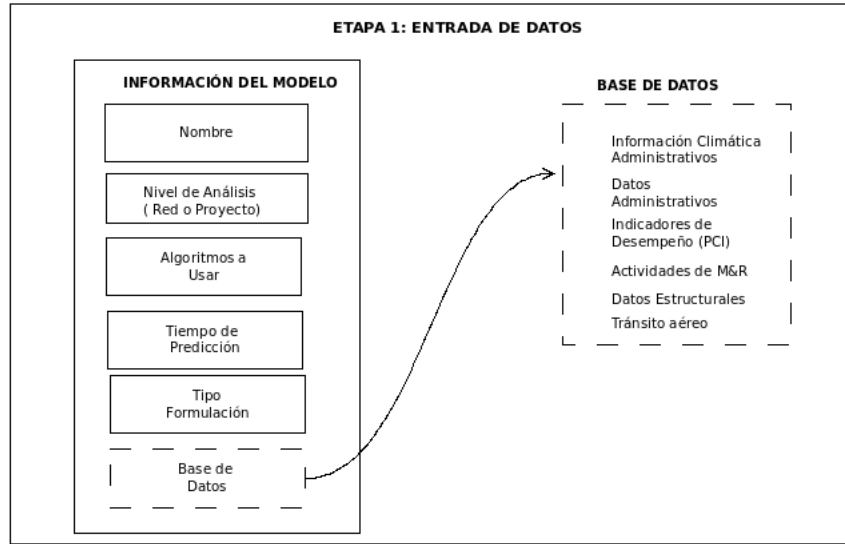


Figura 5.3: Esquema de procesos para Etapa 1.

Fuente: Elaboración Propia.

Respecto a las variables a usar, es recomendable usar las señaladas en la Tabla 5.1, tomando en consideración la información revisada en literatura y el capítulo 4. No obstante, otras variables pueden ser agregada en la medida que se pueda recolectar más datos y la elección definitiva de ellas dependerá de la cantidad disponible de datos y del grado de complejidad del modelo a desarrollar. Respecto a la cantidad de datos mínima para aplicar técnicas de ML no existe un valor definido en la literatura, no obstante, algunos proponen que se debe tener al menos 10 veces la cantidad de variables de entrada o sencillamente usar ML cuando se esté en presencia de miles de datos (Chicco, 2017).

Tabla 5.1: Variables Recomendadas para modelar el indicador PCI en aeropuertos usando ML

Variables Consideradas por categoría					
	Construcción	Clima	Tránsito	Clasificación Admin./ Funcional	Condición Previa
Nivel de Proyecto	Edad del pavimento; Superficie Pavimento (Asfalto ,Hormigón); Espesor; estructura pavimento (convencional, recapado, otro); Actividades de M&R		Operaciones equivalentes acumuladas; Cantidad de Operaciones; Carga acumulada según eje de aeronave.	Rama; Ubicación (central, borde).	PCI
Nivel de Red	Edad del pavimento; Superficie Pavimento (Asfalto ,Hormigón); Espesor; estructura pavimento (convencional, recapado, otro); Actividades de M&R.	Clasificación Koppen (tabla); Temperatura promedio anual; Precipitaciones promedio anual.	Operaciones equivalentes acumuladas; Cantidad de Operaciones; Carga acumulada según eje de aeronave; clasificación categórica sobre nivel del tránsito	Rama; Ubicación (central, borde); Red Primaria-Secundaria; Aeropuerto.	PCI

Fuente: Elaboración Propia.

## Etapa 2: Procesamiento de Datos

En esta segunda etapa, Figura 5.4, se realiza una serie de procesos destinados a preparar la base de datos para los algoritmos a emplear, siendo fundamental para el aprendizaje de los algoritmos (Kotsiantis et al,2006). Los resultados de esta etapa afectan a la calidad en la predicción, en el tiempo que toma el algoritmo para encontrar patrones entre las variables de entrada y salida.

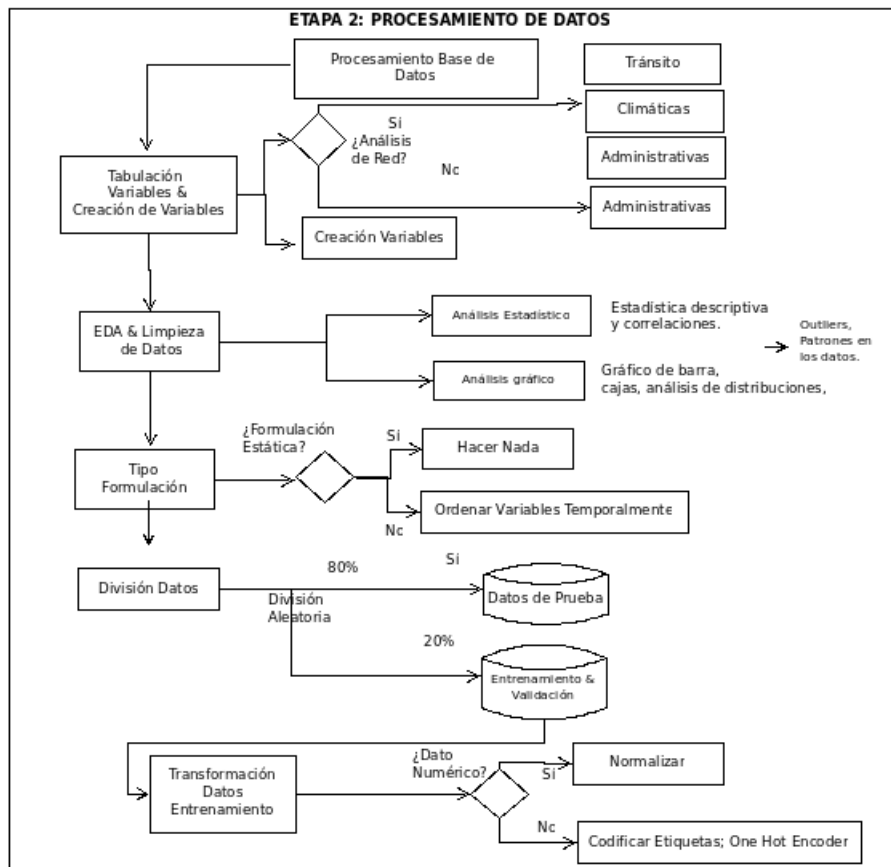


Figura 5.4: Esquema de procesos para Etapa 2.

Fuente: Elaboración Propia.

Para realizar las tareas de procesamiento de datos, se recomienda partir con la tabulación y filtrado de la información de la base de datos en función del tipo de análisis a realizar, es decir, si se considera un análisis de red describir el ejemplo *i*-ésimo del conjunto de datos en función de su zona climática, del tránsito y administrativa: Entendiendo por zona climática, al clima dominante del emplazamiento del aeropuerto, etiquetando dicho aeropuerto con la clasificación recomendada en la Tabla 4.10; respecto al tránsito, adoptando una clasificación en base a nivel de operaciones u otro indicador, como punto de partida usar clasificación de Tabla 4.9; en tanto que la clasificación administrativa se refiere a hacer un análisis por red (primaria, secundaria o pequeños aeródromos)

y/o por familias de pavimentos a nivel general. En el caso que se considere un análisis a nivel de proyecto, no es necesario identificar una variable climática puesto que todas las secciones comparten clima. En cuanto a la clasificación administrativa el análisis puede hacerse por ramas, secciones o unidades muestrales; la selección de dicho análisis debe ir en función de la cantidad de datos, recomendando hacer análisis por sección cuando la cantidad de datos en el tiempo por sección sea considerable y sea verificado con los resultados de precisión de la metodología propuesta.

En segundo lugar, se recomienda hacer un análisis exploratorio de los datos mediante estadística descriptiva, identificando valores inusuales, extremos, incompletos, discontinuidades, posibles relaciones en los datos que sirvan para derivar las primeras hipótesis sobre los datos a emplear. Por lo demás, se deberá considerar la medición de correlaciones entre las variables para evitar el uso de variables redundantes que afecten al desempeño de los datos. El objetivo de este proceso es responder a las preguntas: ¿Qué tipo de datos hay? ¿Falta información? ¿Qué hacer con los datos faltantes y outliers? ¿Qué información adicional se tiene en los datos?.

Para lograr lo anterior, se recomienda hacer un análisis cuantitativo y cualitativo de los datos, tomando en cuenta lo siguiente:

- Para análisis cuantitativo:
  - Usar medidas de dispersión: medias, rangos, tabla frecuencias.
  - Análisis gráfico mediante histogramas, diagramas de caja y bigotes. Diagramas de Dispersión y líneas pueden ser usados para una visión general de los datos.
- Para análisis cualitativo:
  - Tablas de Frecuencia.
  - Gráficos de barra y/o circulares. Útiles para mostrar la composición de los datos.

Por otro lado, 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, produciendo datos ruidosos. Una herramienta útil para identificar este tipo de datos es establecer umbrales lógicos para las variables. Por ejemplo, el valor de PCI varía entre 0 y 100, cualquier valor fuera de los límites es un dato con error y debe ser corregido o eliminado. Además de apoyarse en la estadística descriptiva de los datos, en especial en las medidas de dispersión.

Al mismo tiempo, 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. Ante esta situación varios autores en distintos ámbitos han empleados diferentes técnicas para completar datos que pueden considerarse universales, uno de ellos es Ahmat Zainuri et al. (2015) que para diferentes porcentajes de datos faltantes comparó 6 técnicas para completar datos, entre las cuales se encuentran: sustitución por media y mediana, método de maximización de expectativas (Expectation Maximization-EM), descomposición de valor singular (Singular Value Decomposition-SVD), vecinos más cercanos (K Nearest Neighbor-KNN) y vecinos más cercanos secuencial (Secuencial K Nearest Neighbor-SKNN). Encontrando que para ese problema en particular los métodos de maximización de expectativas y vecinos más cercanos eran los más efectivos. Estos métodos no solo son los únicos y en modelos de desempeño de pavimentos se han aplicado otros como medias móviles para completar y suavizar series de datos (Yang et al., 2003) y regresiones (Abdelaziz et al., 2020). Sin embargo, se debe tener precaución al uso de estas técnicas cuando la cantidad de datos a completar sea elevada, como en el caso de información estructural de los pavimentos evidenciadas en el capítulo 4.

El siguiente paso en el procesamiento de datos es la selección de variables tentativas para modelar y el ordenamiento de la base de datos según el tipo de formulación a probar, estática o dinámica. En el caso de la selección inicial de variables, se recomienda apoyarse en el análisis exploratorio de la base de datos y que tengan relación intuitiva con el deterioro de los pavimentos y al mismo tiempo exista información en todos el grupo de ejemplo. Respecto al tipo de formulación, en el caso de que sea estática (ec. 5.1), no se debe hacer nada, puesto que la variable de salida no depende de estados anteriores en un lapso definido. Por su parte, en el caso dinámico (ec. 5.2) se deben ordenar los pares de entrada y salida del problema 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.

$$C(PCI, t) = f(x_{i,j}) \tag{5.1}$$

$$C(PCI, t) = f(x_{i,j}, PCI_{t-1}, PCI_{t-2}, \dots, PCI_{t-n}) \tag{5.2}$$

Luego los datos serán divididos en un conjunto de entrenamiento y validación, además de un conjunto de prueba. El conjunto de entrenamiento y validación se usa para que algoritmos puedan aprender las relaciones entre las variables de manera general y configurar los hiperparámetros de cada algoritmo. Por su parte, el conjunto de prueba es usado para ver la capacidad de generalización del modelo con datos no vistos en etapas de entrenamiento.

Asimismo, se recomienda dividir el conjunto de datos de manera aleatoria, usando un 80% de los datos para entrenamiento y validación del modelo; apartando un 20% para la etapa de

prueba. Estos porcentajes, pueden variar en función de la cantidad de datos disponibles, costos computacionales de entrenar un modelo y evaluar, representatividad de los datos y distribución de los mismos.

El siguiente proceso señalado en el esquema de la Figura 5.4, es la transformación de datos. Esto es convertir las variables categóricas a numéricas dado que las entradas a cualquier algoritmos son de tipo numérico. Para ello se recomienda usar las paqueterías de ML de Scikit Learn "One Hot Encoder", creando variables ficticias para cada nivel de la variable cualitativa asignando el valor de 1 cuando el dato de entrada corresponda con la entrada y 0 en otros casos. En cuanto a las variables numéricas, es necesario normalizar los datos para prevenir sesgo ante la alta variación entre valores máximos y mínimos en la base de datos (Fausset, 1994). Mediante la normalización todas las variables de la base de datos se modifican a una escala común, buscando no distorsionar las variables ni perder información. Para realizar esta tarea existen diferentes métodos de normalización y estandarización, sin embargo, hay que mantener precauciones de que los escalamientos de variables (ec. 5.3) entre los valores mínimos y máximos pueden no ser convenientes cuando se presentan datos con valores atípicos o ruidosos. El mismo caso sucede cuando se emplea escalado estándar (ec. 5.4), que incluye parámetros como la media y la desviación estándar que son altamente sensible en la presencia de datos anómalos.

$$x_{normalizado} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (5.3)$$

$$x_{estandarizado} = \frac{x - \text{promedio}(x)}{\text{desviacion\_estandar}(x)} \quad (5.4)$$

Donde  $x$ , representa el conjunto de datos asociado a una variable numérica en particular.

### **Etapa 3: Configuración algoritmos y optimización de variables**

En esta etapa se realizará la optimización de las variables inicialmente propuestas y una selección adecuada de los hiperparámetros de cada modelo, usando el conjunto de datos de entrenamiento. Ver Figura 5.5, con el esquema de actividades a realizar en esta etapa.

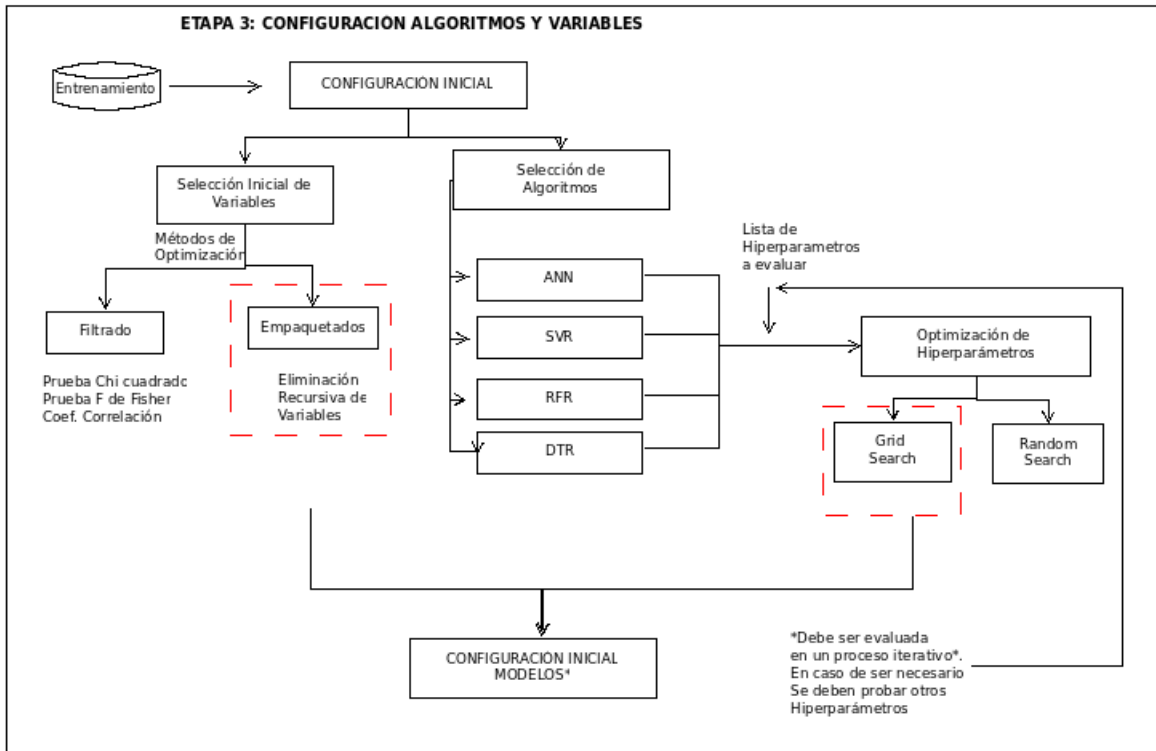


Figura 5.5: Esquema de procesos para Etapa 3.  
Fuente: Elaboración Propia.

En cuanto a la optimización de variables, existen 2 enfoques comúnmente usados: métodos de extracción de variables y métodos de selección de atributos.

Los métodos de extracción de variables, crea variables derivadas de las variables iniciales que se caracterizan por ser informativas y no redundantes; se usa cuando la dimensionalidad del problema es elevada. Una técnica frecuentemente usada es el análisis por componentes principales (PCA-Principal Component Analysis), que utiliza una transformación ortogonal para convertir un conjunto de variables posiblemente correlacionadas en un conjunto de valores de variables linealmente no correlacionadas, llamadas componentes principales.

Por otro lado, respecto a los métodos de selección de variable consisten en distinguir el conjunto de variables que represente de mejor forma el problema. Para ello, existen 3 enfoques principalmente usados: métodos de filtrado, envoltura y embebidos. Los de filtrado emplean al menos un conjunto de entrenamiento para medir la correlación entre las variables de entrada y la salida, así como también la relación existente entre ellos para evitar redundancia, obteniendo resultados rápidamente. En cambio, los métodos de envoltura consideran la selección de todas las combinaciones posibles de subconjuntos de variables de entrada para el modelo, buscando optimizar la capacidad de generalización de un modelo de ML entrenado, por ende requiere mayor tiempo de

procesamiento. Por último, los métodos integrados, combinan cualidades de los métodos de filtrado y envoltura, incorporándose directamente en el algoritmo de aprendizaje durante el entrenamiento, de modo de que los parámetros se ajustan progresivamente de acuerdo a la relevancia de las variables en el rendimiento del modelo, eliminando aquellas variables redundantes o de irrelevancia para el modelo (May et al., 2011).

En este caso, se recomienda usar un método de filtrado basado en el método de envoltura, por la capacidad de precisión a alcanzar respecto a métodos de filtro que hacen un análisis univariante de las variables de entrada con la variable objetivo. Por lo demás, los métodos de filtro tienen dificultades para encontrar el mejor subconjunto de variables en situaciones que no hay suficientes datos para modelar correlaciones estadísticas, en cambio los métodos de envoltura no poseen este problema. Cabe señalar, que para trabajar con un método de envoltura se debe seleccionar un algoritmo de ML, con el fin de medir el grado de desempeño de las elecciones de variables durante el proceso de exploración del mejor conjunto de variables que definan el problema.

Otra parte importante en la etapa 3, es seleccionar los algoritmos y con ello una configuración inicial de hiperparámetros de cada uno de ellos. Esta configuración inicial es optimizada posteriormente en función de los resultados de precisión en el conjunto de entrenamiento y validación. Unas herramientas útiles para esta tarea es la función Grid search y Random Search de Scikit Learn. Grid Search hace una búsqueda exhaustiva sobre una lista de valores de hiperparámetros de un algoritmo, encontrando la combinación ideal de parámetros que proporcionen mayor precisión, tomando en cuenta no caer en el sobre ajuste de los algoritmo, siendo posible usar validación cruzada en el proceso de búsqueda. En cambio, Random Search hace una búsqueda aleatoria entrenando y evaluando una serie de modelos tomando extractos aleatorios de un conjunto predeterminado de distribuciones de hiperparámetros. Aunque Grid Search emplee más recursos computacionales se recomienda por la exactitud de su predicción.

#### **Etapa 4: Entrenamiento y evaluación de modelos**

Una vez seleccionada las variables óptimas y la configuración de hiperparámetros de los algoritmos, se ejecuta la etapa 4, indicada en la figura 5.6.

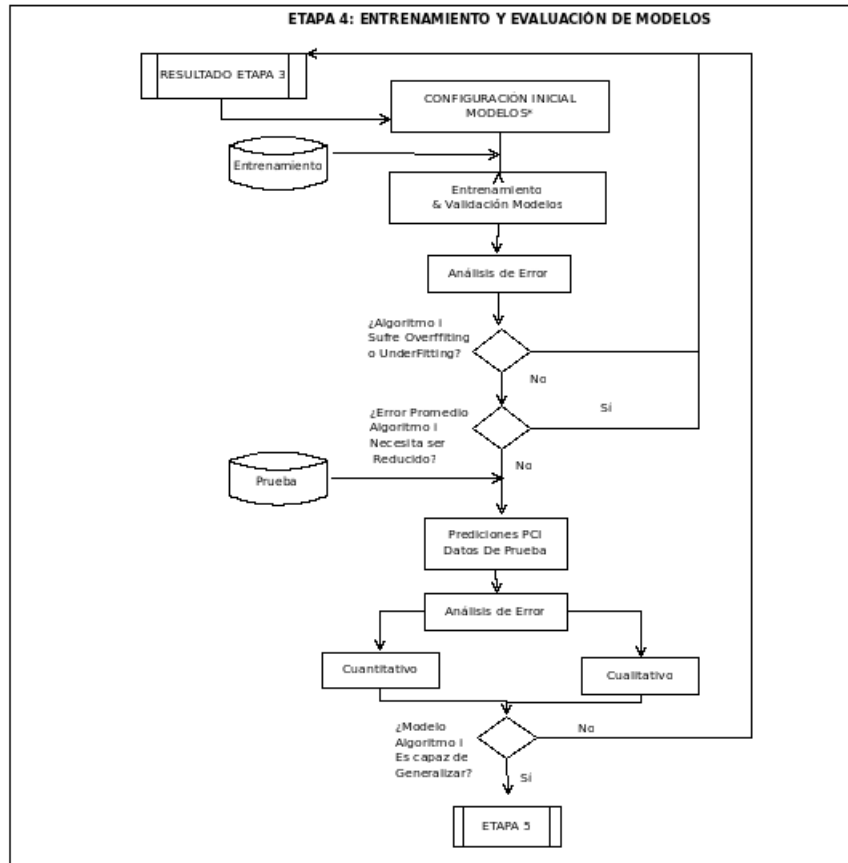


Figura 5.6: Esquema de procesos para Etapa 4.  
Fuente: Elaboración Propia.

En esta etapa, se deben entrenar los modelos usando esta configuración inicial, aplicando al mismo tiempo técnicas de validación cruzada k-fold con repetición al conjunto de entrenamiento-validación, que consiste en dividir los datos en k grupos, donde k-1 se usan para entrenar y el resto para validar el modelo, este proceso se repite n veces, obtenido como resultado una lista errores por cada grupo. El error final, es señalado como el promedio de los grupos, esto compensa las desviaciones que pueden surgir con la aleatoriedad de los grupos. Por otro lado, la comparación entre los errores de entrenamiento y validación, dan cuenta de la existencia de sobre ajuste o bajo ajuste, que en caso de existir se deberá probar con una nueva lista de hiperparámetros hasta satisfacer que los errores de entrenamiento y validación no posean altas diferencias y además posean una precisión razonable. Cabe señalar, que este proceso se hará por algoritmo y en caso de que ninguna configuración de resultados, se deberán explorar las opciones señaladas en el capítulo 2 para solucionar problemas de sobre ajuste y bajo ajuste.

Luego, de satisfacer un nivel de precisión y obtener un correcto ajuste, se procede a probar el aprendizaje de los algoritmos en el conjunto de prueba. Para ello, Fathi et al. (2019) propone una

evaluación de los algoritmos en términos cualitativos y cuantitativos mostrado en la Figura 5.7.

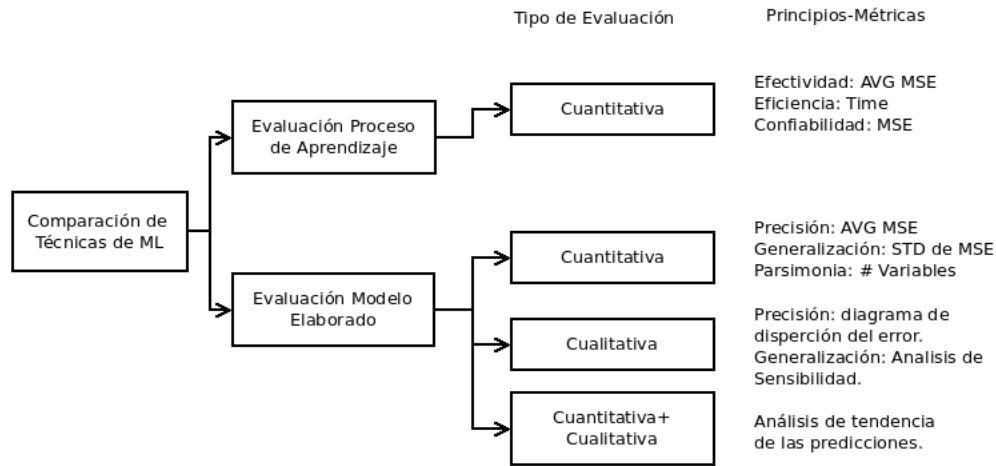


Figura 5.7: Componentes a considerar en Modelos de Desempeño de Pavimentos.

Fuente: Adaptación Fathi et al. (2019)

Por su parte, en la figura 5.7 el término parsimonia hace referencia a cuando existan algoritmos con igual error se debe seleccionar el más simple. Mientras que el término generalización, hace referencia a la capacidad de extrapolar los resultados a conjuntos de datos diferentes.

Algunas métricas con frecuencia usadas se describen a continuación:

- Error cuadrático medio (Mean Square Error-MSE): para cada punto se determina la diferencia cuadrada entre las predicciones y el valor objetivo, obteniendo un valor promedio. Un valor de MSE () alto indica la baja calidad predictiva y en algunos casos la presencia de gran cantidad de datos ruidosos o anómalos.

$$MSE = \frac{1}{N} \cdot \sum (y_{i,est} - y_{i,ob})^2 \quad (5.5)$$

- Raíz del Error cuadrático medio (Root Mean Square Error-RMSE): es la raíz de MSE. La raíz cuadrada permite que la escala de errores sea igual a la de objetivos.

$$RMSE = \sqrt{\frac{1}{N} \sum (y_{i,est} - y_{i,ob})^2} \quad (5.6)$$

- Error Absoluto medio (Mean Absolute Error-MAE): el error se calcula como el promedio entre las diferencias absolutas entre la variable estimada y la objetivo. A diferencia del MSE se puntúa de manera lineal y no cuadrático; la sensibilidad a valores atípicos es menor que al emplear MSE.

$$MAE = \frac{1}{N} \cdot \sum |y_{i,ob} - y_{i,est}| \quad (5.7)$$

Donde:

$y_{i,est}$  :valor estimado por el modelo para el ejemplo i-ésimo de la base de datos.

$y_{i,obj}$  valor objetivo por el modelo para el ejemplo i-ésimo de la base de datos.

De igual modo, otras investigaciones recurren al uso de test de hipótesis para evaluar el grado de relación entre los algoritmos evaluados, en términos de los errores medios cometidos en diferentes conjuntos de datos en el proceso de validación cruzada (Luengo et al., 2009; Trawinski et al., 2012). En consecuencia, esta técnica de evaluación y otras, serán consideradas en la metodología propuesta, tomando en cuenta la objetividad de los métodos estadísticos señalados. En este caso se recomienda el uso de test de hipótesis cuando los resultados evidencien cierta similitud en los datos. Para errores con distribución normal usar prueba t-student y en otro caso Mann Whitney.

## **Etapas 5: Resumen de Predicciones**

En la etapa de post procesamiento de datos, se analiza el resultado de los algoritmos empleados y se selecciona el que provee mejores resultados en términos de predicción. Usando las configuraciones del algoritmo de mejor desempeño, se procede a realizar la predicción de la condición del pavimento en el tiempo. Entregando resultados en término de tablas con las predicciones para los siguientes años y gráficos de los modelos de desempeño. A partir de ellos es posible evaluar la evolución del deterioro para años venideros e identificar los pavimentos con necesidades urgentes. En la Figura 5.8, los procesos de la etapa señalada.

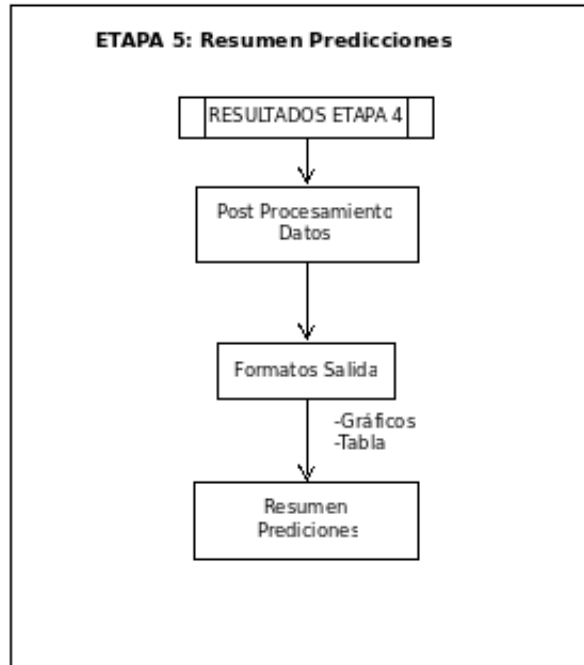


Figura 5.8: Esquema de procesos para Etapa 5.  
Fuente: Elaboración Propia.

# Capítulo 6

## Aplicación Metodología para elaborar Modelos de Desempeño usando ML

En este capítulo se aplica la metodología propuesta en el capítulo 5, realizando inicialmente un análisis a nivel de proyecto y luego uno a nivel de red.

Una parte de este trabajo fue enviado a la revista International Journal of Pavement Engineering, bajo el título "Development of an airport pavement performance model using Machine Learning: A Chilean case study". Correspondiente a la aplicación a nivel de proyecto de la metodología propuesta.

### 6.1 Aplicación Metodología: Nivel de Proyecto

En esta parte, se hace un análisis a nivel de proyecto, es decir, se toman en cuenta los datos asociados a una infraestructura en específica, en cuyo caso corresponden a los datos del Aeropuerto Andrés Sabella facilitada por la DAP de Chile. Por otro lado, es importante señalar que la elección de este aeropuerto se basa principalmente en la disponibilidad de datos de auscultación disponible.

#### 6.1.1 Datos de Entrada

La base de datos usada comprende información de 16 secciones pertenecientes a la pista y calles de rodaje, previo procesamiento, recogidos anualmente entre el 2013 y 2019. Esta información fue recopilada a partir de informes de auscultación por parte de la sociedad concesionaria a cargo del aeropuerto Andrés Sabella en dicho período.

Respecto a la información recopilada, está incluye la condición del pavimento (PCI), actividades de M&R, información de los materiales, espesores de las capas del pavimentos e información del tránsito aéreo otorgada por la DGAC comprendida entre el año 2000 y 2019. Aunque varios factores contribuyen al deterioro del pavimento, en este estudio se incluyen aquellos que son fácil de medir, accesibles y que tienen directa relación con el desempeño del pavimento (Solminihac et al., 2018).

Asimismo, aún cuando la variable asociada al tránsito aéreo puede modelarse de múltiples formas como: operaciones acumuladas de la aeronave equivalente de diseño, suma acumulada de peso máximos de despegue y pesos máximos de aterrizaje, consideración de un factor de uso de rama, ubicación de la línea de aeronave, entre otras (Kwak et al., 2020; Barua et al., 2020). En este trabajo se modelarán 3 escenarios distintos, tomando en cuenta esta variable y que se describen a continuación:

- **Escenario 1:** Considera la variable tránsito aéreo como el número de operaciones equivalentes de la aeronave de diseño. Esta otorga una aproximación para cuantificar las diferentes cargas y configuraciones de trenes de aterrizaje (Al-Suleiman et al., 1996; Kwak et al., 2020).
- **Escenario 2:** Cuantifica el tránsito aéreo como las cargas acumuladas en el pavimento desde su construcción. Agregando en variables separadas la carga de aeronaves con tren de aterrizajes diferentes.
- **Escenario 3:** No considera la variable del tránsito aéreo y sirve de base para comprender la influencia de esta variable en el estudio.

El resto de variables asociadas al clima, estructura, materiales, entre otras. Se considera por igual en todos los modelos. Una descripción de las variables utilizadas se indica en la Tabla 6.1

Tabla 6.1: Descripción de variables y escenarios usados.

Variable	Descripción	Escenario		
		1	2	3
Rama	Una parte identificable de la red que tiene una función específica.	X	X	X
Tipo de Pavimento	Pavimento convencional o recapado	X	X	X
Edad	Antigüedad del pavimento desde el año de construcción o rehabilitación (año).	X	X	X
Espesor	Espesor superficial del pavimento (cm).	X	X	X
PCI	PCI actual	X	X	X
Tráfico acumulado de aeronaves de diseño equivalente	Salidas anuales equivalentes futuras acumulada.	X	X	
Tráfico acumulativo dual en tándem	Tráfico acumulado futuro dual en tándem (operaciones de despegue).		X	
Doble rueda de tráfico acumulativo	Futuro acumulado de tráfico de doble rueda (Operaciones de despegue).		X	

Fuente: Elaboración Propia.

Es importante señalar que las variables asociadas al tránsito aéreo son procesadas en la etapa 2, es decir, se calcula la carga acumulada de aeronave equivalente de diseño y la carga acumulada de rueda doble y doble en tándem. Además cabe señalar, que dado que no es un problema de diseño el uso del concepto de conversión a la aeronave de diseño, en este problema es usado meramente para cuantificar operaciones en una aeronave común, esto independiente de que las secciones estén construidas de manera diferente.

En el anexo E, se muestra la base de datos utilizada. En tanto que un extracto de ella se indica en la Tabla 6.2.

Tabla 6.2: Extracto base de datos Aeropuerto Andrés Sabella. Incluye información sobre condición de pavimento, tipo de pavimento, año de construcción y otros.

Año Evaluación	Sección	Año Construcción	Nomen.	Espesor	Tipo Pavimento	Edad	PCI	PCI t+1
2013	PI-1	2006	ACPC	16	Recapado	7	83	83
2018	PI-4	2006	ACPC	16	Recapado	12	79	79
2018	PI-5	2006	ACPC	11	Recapado	12	99	99
2014	RA-2	2010	AC	10	Convencional	4	100	100
2013	DE-1	2010	ACPC	10	Recapado	3	93	89
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.
2015	PI-3	2006	ACPC	16	Recapado	9	88	85

Fuente: Elaboración Propia.

Por lo demás, se ha de considerar un análisis dinámico de las variables asociado al tránsito aéreo y el indicador PCI.

### 6.1.2 Procesamiento de datos

El procesamiento de la base de datos en esta parte ha de considerar la creación de variables y tabulación según nivel de proyecto, análisis exploratorio de datos y con ello limpieza, ordenamiento en series de tiempo, escalamiento de variables y división de datos.

En primera instancia, las variables a crear son las variables asociadas al tránsito aéreo. Para ello, en este estudio las aeronaves consideradas relevantes son aquellas sobre 13,608 [kg] o 30,000 lb, con una frecuencia de operación promedio de 12 operaciones por año desde la edad de construcción del pavimento, tomando como referencia la circular 150/5350-6D de la FAA (Federal Aviation Administration). Luego, la variable tránsito aéreo se representa bajo el concepto de carga acumulada y bajo el concepto de aeronave de diseño equivalente, que para este caso es la B763. La Tabla 6.3, muestra un ejemplo de la conversión realizada en cada caso.

Tabla 6.3: Ejemplo conversión aeronave de diseño equivalente.

Año	Modelo Aeronave	MTOW[ton]	Tipo de Tren	Operaciones	# Ruedas	W2	Factor Conversión	W1	Operaciones equivalentes
2006	A319	70	D	1720	2	16,63	0,64	34,08	182
2006	A322	76	D	65	2	18,05	0,64	34,08	21
2006	A322	77	D	522	2	18,29	0,64	34,08	98
2006	B732	57	D	336	2	13,54	0,64	34,08	39
2006	B732	58	D	1668	2	13,78	0,64	34,08	112
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
2010	A318	63	D	2700	2	14,96	0,64	34,08	188
2010	A319	70	D	648	2	16,63	0,64	34,08	92
2010	A320	77	D	1519	2	18,29	0,64	34,08	214
2010	B732	58	D	1066	2	13,78	0,64	34,08	84
2010	B733	63	D	143	2	14,96	0,64	34,08	27

Fuente: Elaboración Propia.

Por su parte, dado que la antigüedad de las secciones que se disponen corresponde a los años 2006 y 2010, se debe compatibilizar con el registro de datos, la cantidad de operaciones acumuladas a partir de la edad de construcción. Para ello la Tabla 6.4, recoge la cantidad de operaciones equivalentes de la aeronave de diseño B763, junto con la carga acumulada para rueda doble y rueda doble en tandem.

Tabla 6.4: Compendio con valores acumulados de aeronave de diseño equivalente y carga acumuladas según tipo de eje.

Año construcción	Año	Operaciones Equivalentes acumuladas	Carga acumulada de rueda doble [t] /100	Carga Acumulada rueda doble en Tandem [t] /100
2010	2010	5149	3400	24
	2011	13399	7913	26
	2012	24507	13764	35
	2013	37767	20436	67
	2014	52330	27733	95
	2015	65511	34274	106
	2016	77726	39989	108
	2017	88570	45153	108
	2018	101880	50836	179
	2019	116921	56815	333
2006	2006	2887	1670	9
	2007	5752	3306	11
	2008	9045	5540	26
	2009	12477	8001	28
	2010	17626	11401	52
	2011	25876	15914	54
	2012	36983	21766	63
	2013	50244	28437	95
	2014	64807	35735	123
	2015	77988	42276	134
2016	90203	47990	136	
2017	101047	53154	136	
2018	114357	58838	207	
2019	129398	64816	361	

Fuente: Elaboración Propia.

Por su parte, la limpieza consiste en remover aquellos datos inconsistentes y con información faltante. Para este estudio, las secciones que experimenten un aumento en el valor de PCI mayores a 5 puntos sin actividades previas de M&R son eliminadas. El límite de 5 puntos considera el error aceptable en la estimación de PCI de una sección, según la norma ASTM (American Society for Testing and Materials) D 5340. Por otro lado, este estudio deja afuera aquellos pavimentos de hormigón, por ser un número reducido en comparación a pavimentos de asfalto, además de existir probablemente actividades de mantención de las que no se posee registros, puesto a que en aquellos pavimentos existe una condición excelente pasados los 20 años. Asimismo las secciones de plataforma quedan afuera de este análisis por estar compuesta en su mayoría de pavimentos de hormigón. Ver Figura 6.1.

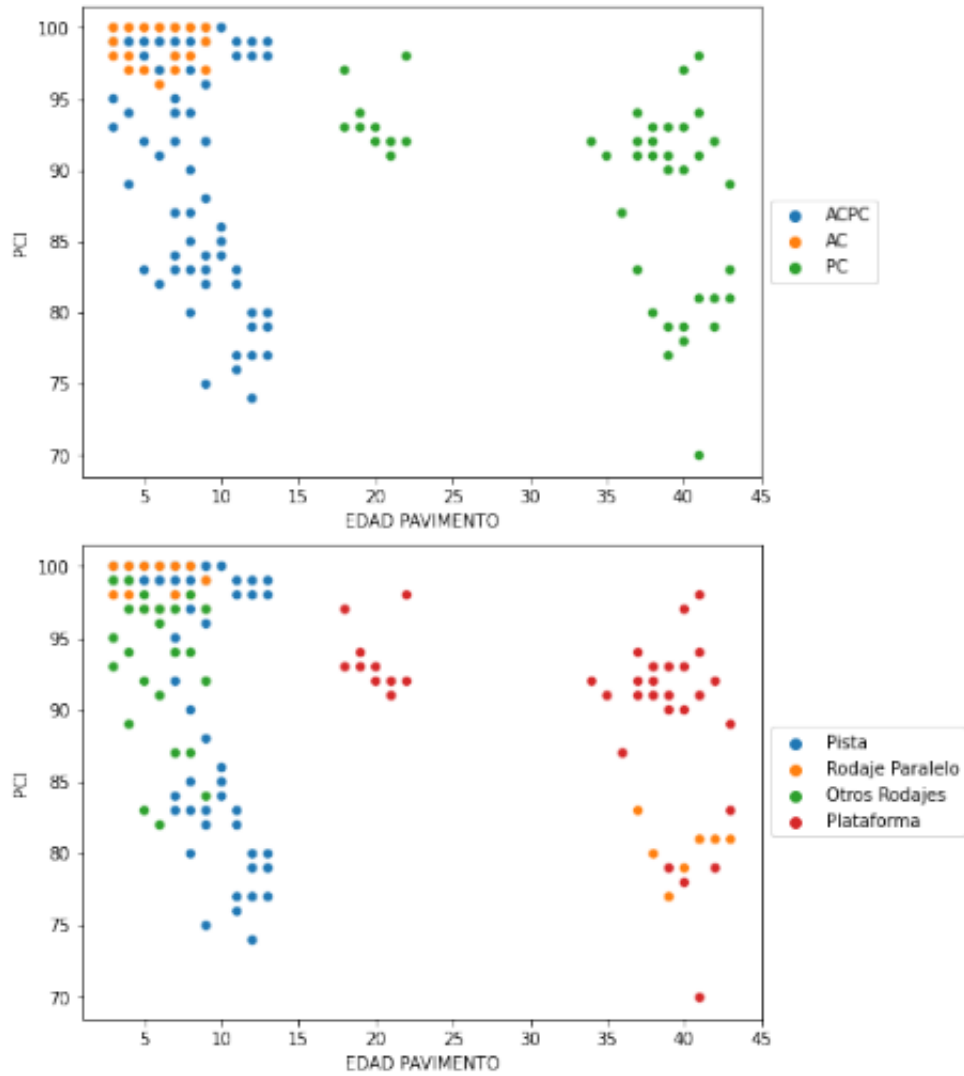


Figura 6.1: Distribución de PCI por tipo de pavimento y rama.  
 Fuente: Elaboración Propia.

Adicionalmente la Tabla 6.5 presenta un análisis descriptivo de los datos previamente limpiados y filtrados.

Tabla 6.5: Descripción de variables numéricas de base de datos filtrada.

	Espesor	Edad	PCI	Salidas anuales equivalentes de diseño	Tráfico acumulado dual en tándem	Doble rueda de tráfico acumulativo
# datos	95	95	95	95	95	95
promedio	11.71	6.98	93.91	88483.97	165.83	45440.68
desviación Estandar	2.48	2.60	7.49	22699.07	86.31	10623.80
min.	10	3	74	52330.26	94.86	27733.37
25%	10	5	88.5	65511.17	108.32	35734.55
50%	10	7	98	88570	134.36	45153.29
75%	11	8	100	101879.76	179	53154.47
max.	16	12	100	129397.92	361.28	64815.83

Fuente: Elaboración Propia.

Puesto que se considera un análisis dinámico, se debe hacer un ordenamiento en series temporales, que consiste en usar como variable de entrada valores en un tiempo anterior de la variable que se desea predecir en un tiempo posterior, en este caso se hace uso del valor del indicador PCI anterior a la predicción siguiente.

En cuanto a la división de datos, esta se hace usando Scikit Learn. En este punto, es importante resaltar que los datos son divididos aleatoriamente, y tanto los conjuntos de entrenamiento-validación y prueba deben tener similar distribución, puesto que luego los datos de prueba serán normalizados a partir del conjunto de entrenamiento-validación cuando se desee realizar predicciones. En este caso la Tabla 6.6, describe los conjuntos de entrenamiento-validación y prueba.

Tabla 6.6: Descripción de variables numéricas, para conjunto de entrenamiento-validación y prueba

	Espesor		Edad		PCI		Salidas anuales equivalentes de diseño acumulada		Tráfico acumulado dual en tándem		Tráfico acumulado Rueda Doble	
	Entren.-Valid.	Prueba	Entren.-Valid.	Prueba	Entren.-Valid.	Prueba	Entren.-Valid.	Prueba	Entren.-Valid.	Prueba	Entren.-Valid.	Prueba
# Datos	76	19	76	19	76	19	76	19	76	19	76	19
Promedio	11,33	13,21	6,82	7,63	94,88	90	87.982,24	90490,91	167,47	159,25	45099,49	46805,44
Desviación Estándar	2,18	3,03	2,58	2,67	6,76	9,07	23.067,19	21641,61	88,51	78,79	10747,80	10277,94
min	10	10	3	3	76	74	52.330,26	52330,26	94,86	94,86	27733,37	27733,37
25%	10	10	5	6	92	82,5	65.511,17	77726,09	108,32	108,32	35734,55	39988,72
50%	10	16	7	7	98	94	88.570,00	88570,00	134,36	134,36	45153,29	45153,29
75%	11	16	8	9,5	100	99	101.879,76	101879,76	179,00	179,00	53154,47	51995,41
max	16	16	12	12	100	100	129.397,91	129397,91	361,28	361,28	64815,83	64815,83

Fuente: Elaboración Propia.

Al mismo tiempo, la normalización de variables es llevada a cabo usando One Hot Encoder de la librería de Scikit-Learn que binariza las variables, creando variables ficticias para cada nivel de

la variable cualitativa asignando el valor de 1 cuando el dato de entrada corresponda con la entrada y 0 en otros casos. La Tabla 6.7, muestra el resultado de las variables escaladas y ya binarizadas.

Tabla 6.7: Ejemplo de binarización y escalamiento de variables de entrada (Escenario 1) .

Espesor	Edad	PCI	Salidas anuales equivalentes de diseño acumulada	Rama _Calle de Rodaje	Tipo pavimento _Recapado
-0,61	-1,49	0,02	-1,56	1	1
-0,15	-0,32	0,61	0,03	0	1
2,16	0,46	-0,73	-0,44	0	1
-0,61	-0,32	-1,92	0,03	1	1
-0,61	-1,49	0,61	-1,56	1	0

Fuente: Elaboración Propia.

### 6.1.3 Configuración variables y algoritmos

En esta etapa se hace una optimización de las variables inicialmente consideradas para el diseño. En este estudio se utiliza el método recursive feature elimination with cross-validation(RFECV), que consiste en entrenar un modelo con una técnica base a partir de con un conjunto inicial de características y eliminar la característica más débil hasta que se alcanza el número especificado de características que optimizan el desempeño del problema. En este caso la técnica base escogida es Random Forest considerando validación cruzada con 5 pliegues para todos los escenarios analizados.

En la Figura 6.2, presentan los resultados obtenidos tras aplicación, observando que para los escenarios 1 y 2, se necesitan 5 variables para alcanzar el mejor desempeño. Mientras que para el escenario 3, se necesitan 6 variables.




Figura 6.2: Resultados RFECV por escenario.  
Fuente: Elaboración Propia.

Por su parte, la Tabla 6.8, resume la importancia de cada variable según el escenario analizado, en términos de  $R^2$ . Los resultados, indican que los 3 escenarios son altamente dependientes del PCI en el tiempo anterior a la predicción ( $\geq 94\%$ ), seguido de la edad del pavimento ( $\geq 2.5\%$ ) y otras variables relacionadas con el tránsito, pero en un porcentaje menor. Aun así, este estudio considera esas variables en la modelación dado que incrementan la precisión del modelo en términos de  $R^2$ , según lo señalado en la Figura 6.2.

Tabla 6.8: Importancia de variables por escenario de estudio.

Escenarios	Variable	Importancia %
1	PCI	94.59
	Edad	2.98
	Operaciones equivalentes acumuladas de la aeronave de diseño	1.04
	Espesor	0.63
	Rama_Calle_de_Rodaje	0.60
	Tipo de pavimento_Recapado	0.17
	2	PCI
2	Edad	2.55
	Cumulative traffic dual wheel	1.37
	Rama_Calle_de_Rodaje	0.72
	Espesor	0.63
	3	PCI
3	Edad	3.60
	Rama_Calle_de_Rodaje	0.85
	Espesor	0.53
	Tipo de pavimento_Recapado	0.18

Fuente: Elaboración Propia.

Con el fin de ofrecer una comparación exhaustiva, diversos algoritmos de ML fueron revisadas: ANN, RFR, TDR and SVR. El fin es seleccionar el algoritmo que ofrezca mejores resultados de precisión para el problema de análisis, tomando en consideración que a priori no se puede saber que algoritmo de ML proveerá mejores resultados (Kargah-Ostadi, 2014; Wolpert, 1996).

Luego se debe configurar los hiperparámetros de cada algoritmo elegido, estos no dependen de los datos y se configuran con anterioridad a la etapa de entrenamiento (Géron, 2019). En este estudio, se utiliza la función Grid Search de Scikit learn que hace una búsqueda exhaustiva de diferentes combinaciones de hiperparámetros de un conjunto de hiperparámetros de entrada, seleccionando la mejor combinación mediante alguna medida de desempeño.

Los hiperparámetros usados y testeado en cada algoritmo se presentan en la Tabla 6.9. Aquellos hiperparámetros no indicados, se consideran por defecto en la configuración de las paqueterías de ML de Scikit Learn. Cabe señalar que la selección de hiperparámetros se hace a partir de Repeated K-fold cross-validation, esto proporciona una estimación más precisa del error evitando el ruido en la estimación que se comete al evaluar 1 sola vez.

Tabla 6.9: Resultados del ajuste de hiperparámetros con Grid Search de Scikit Learn.

Algoritmo	Hiperparámetros	Hiperparámetros Probados	Hiperparámetros Seleccionados		
			Escenario 1	Escenario 2	Escenario 3
ANN	Capas Ocultas/ (Cantidad Neuronas)	[(10, ), (10, 10), (10, 10, 10)]	(10,)	(10,)	(10,)
	Función Activation	[ <i>relu, logistic</i> ]	relu	relu	relu
	alpha	\$(0.0001,0.05,5,50,75,100,500)\$ <sup>4</sup>	50	50	50
RFR	Prof. Máxima del Árbol	[1, 2, 4, 6]	6	6	6
	El número de características a considerar cuando se busca la mejor división:	[ <i>auto, sqrt, log2</i> ]	auto	auto	log2
SVM	Kernel	[ <i>rbf, linear, poly</i> ]	rbf	rbf	rbf
	C	[0.1, 1, 10, 100]	100	100	100
DTR	Prof. Máxima del Árbol	[1, 2, 4, 6]	6	6	6
	Número mínimo de muestras necesarias para dividir un nodo interno	[1, 2, 4, 6]	4	2	4
	Número mínimo de muestras necesarias para estar en un nodo hoja.	[1, 2, 4, 6]	2	2	2

Fuente: Elaboración Propia.

### 6.1.4 Entrenamiento y Evaluación de Modelos

Una vez realizado el proceso de selección de atributos y ajuste de parámetros, se realiza un análisis cuantitativo y cualitativo de los algoritmos usados en cada escenario.

En términos cuantitativos, la Tabla 6.10 muestra los resultados promedios (AVG) obtenidos de las métricas MSE, MAE y  $R^2$ , para el conjunto de datos de entrenamiento y validación . Observando que el algoritmo DTR para el escenario 3 es el modelo con peor rendimiento con un valor promedio de  $R^2 = 0.85(0.12)$ ,  $MAE = 1.59(0.52)$  y  $MSE = 2.58(0.84)$  en el conjunto de validación. Asimismo, los resultados muestran una gran capacidad predictiva de los modelos, observando que las diferencias obtenidas en el conjunto de entrenamiento y validación no son sustanciales, lo que sugiere que los modelos ajustados no tienen tendencia a sufrir overfitting (sobre ajuste).

Tabla 6.10: Evaluación cuantitativa de resultados en etapa entrenamiento-validación, según Escenarios 1, 2 y 3.

Escenario	Algoritmo	AVG R2 (STD)		AVG MAE (STD)		AVG MSE (STD)	
		Entrenamieto	Validación	Entrenamieto	Validación	Entrenamiento	Validación
1	ANN	0.95 (0.01)	0.91 (0.09)	1.3 (0.08)	1.46 (0.36)	1.74 (0.11)	1.95 (0.51)
	RFR	0.99 (0)	0.89 (0.11)	0.55 (0.05)	1.38 (0.36)	0.89 (0.07)	2.21 (0.49)
	SVM	0.99 (0)	0.93 (0.08)	0.39 (0.05)	1.09 (0.37)	0.88 (0.12)	1.68 (0.54)
	DTR	0.98 (0)	0.85 (0.12)	0.59 (0.07)	1.57 (0.5)	0.97 (0.12)	2.55 (0.78)
2	ANN	0.95 (0.01)	0.92 (0.08)	1.23 (0.09)	1.37 (0.35)	1.69 (0.12)	1.88 (0.49)
	RFR	0.99 (0)	0.88 (0.11)	0.56 (0.05)	1.4 (0.37)	0.91 (0.08)	2.26 (0.52)
	SVM	0.98 (0)	0.94 (0.07)	0.42 (0.04)	1 (0.32)	0.93 (0.11)	1.56 (0.49)
	DTR	0.98 (0)	0.86 (0.11)	0.61 (0.08)	1.54 (0.5)	0.98 (0.13)	2.49 (0.8)
3	ANN	0.95 (0.01)	0.91 (0.09)	1.3 (0.08)	1.44 (0.36)	1.75 (0.12)	1.96 (0.51)
	RFR	0.99 (0)	0.9 (0.09)	0.6 (0.06)	1.39 (0.4)	0.9 (0.07)	2.09 (0.5)
	SVM	0.98 (0)	0.92 (0.1)	0.47 (0.05)	1.15 (0.35)	1.02 (0.11)	1.82 (0.54)
	DTR	0.98 (0.01)	0.85 (0.12)	0.63 (0.07)	1.59 (0.52)	1.02 (0.14)	2.58 (0.84)

Fuente: Elaboración propia.

Para asegurar la capacidad de generalización en las predicciones, los modelos son probados en un conjunto de datos no visto durante las etapas de aprendizaje, evaluando si las respuestas predichas son acertadas o no a los valores de PCI medidos. Un completo análisis de los errores cometidos en la etapa de prueba se indica en la Tabla 6.11.

Tabla 6.11: Resultados etapa de prueba Escenarios 1, 2 y 3.

Algorithm	Escenario 1			Escenario 2			Escenario 3		
	R2	MAE	MSE	R2	MAE	MSE	R2	MAE	MSE
ANN	0.95	1.59	3.59	0.94	1.90	4.60	0.95	1.47	3.54
RFR	0.98	0.81	1.74	0.97	0.97	2.01	0.98	0.82	1.58
SVM	0.94	1.57	4.96	0.93	1.61	5.16	0.93	1.59	5.15
DTR	0.92	1.61	6.39	0.91	1.71	6.70	0.92	1.62	6.39

Fuente: Elaboración propia.

Los resultados muestran que, dentro de los tres escenarios estudiados, el desempeño del algoritmo de RFR fue superior, alcanzando valores de  $R^2 > 0.97$ ,  $MAE < 0.97$  y  $MSE < 2.01$ . No obstante, a ello el rendimiento del resto de los algoritmos es adecuado obteniendo valores  $R^2 > 0.9$  y  $MAE < 1.9$  PCI. En cuanto a los escenarios estudiados cabe señalar que, el escenario 3 presenta mejores resultados con  $R^2 = 0.98$ ,  $MAE = 0.82$  y  $MSE = 1.58$ . Esto sugiere que para el experimento realizado la inclusión de la variable tránsito aéreo, no significa una mejora en la calidad de predicción. Para validar esta hipótesis se realiza una comparación de los modelos por medio de un test de hipótesis, con el fin de establecer si la diferencia en términos de errores promedios entre los escenarios modelados con RFR es real o es una casualidad estadística. Para ello, se dispone de los errores promedios obtenidos en el proceso de validación cruzada con repetición, provenientes

de un proceso aleatorio y que son usadas para definir las muestras de cada modelo a comparar, en términos de la métrica MAE en los 3 escenarios. En tal caso, se realizó un test hipótesis no paramétrico de Mann Whitney dada la no normalidad de las distribuciones muestral para el escenario 3, aplicando el test Shapiro Wilk con p-value=0.0257. Luego se define la hipótesis nula y alternativa del test de Mann Whitney como:

- Hipótesis Nula:  $H_0 = \mu_1 = \mu_2$ , donde  $\mu_1$  y  $\mu_2$  son las medias del error en términos de MAE de cada grupo de evaluación.
- Hipótesis Alternativa,  $H_1 : \mu_1 \neq \mu_2$ .
- La Hipótesis Nula, es rechazada cuando el valor de  $p \leq 0.05$

Tabla 6.12: Resultados test de hipótesis.

Hipótesis	$\mu_1$	$\mu_2$	$\alpha$	p-value
$H_0:\mu_1=\mu_2 ; H_1:\mu_1 \neq \mu_2$	AVG MAE (Escenario 3-RFR)	AVG MAE (Escenario 1-RFR)	0.05	0.152
$H_0:\mu_1=\mu_2 ; H_1:\mu_1 \neq \mu_2$	AVG MAE (Escenario 3-RFR)	AVG MAE (Escenario 2-RFR)	0.05	0.179

Fuente: Elaboración propia.

Los resultados de la prueba de hipótesis planteada se presentan en la Tabla 6.12, indicando que no existe evidencia estadística para rechazar la hipótesis nula, es decir, las medias de los errores de los modelos RFR en los 3 escenarios son iguales. En efecto, los modelos poseen igual habilidad para predecir el valor de PCI en el tiempo, por ende, es recomendable usar un modelo que no considere el tránsito aéreo como variable explicativa del fenómeno en análisis. Probablemente este resultado es atribuible a las correlaciones existentes entre la edad del pavimento y la variable tránsito caracterizada.

Por otra parte, un análisis cualitativo es llevado a cabo comparando los valores medidos y predichos tanto para el conjunto de entrenamiento y prueba, para el modelo RFR escenario 3, ver Figura 6.3. La Figura 6.3 (a) y 6.3 (b), sugieren que la predicción del modelo en el conjunto de testeo tiende a subestimar los valores de PCI predichos. En cuanto a las Figuras 6.3 (c) y 6.3 (d) se observa que el patrón de residuos hallado es al azar, sin una tendencia ni puntos atípicos. En general, los residuos se encuentran en torno a cero, con bajo bias y baja varianza.

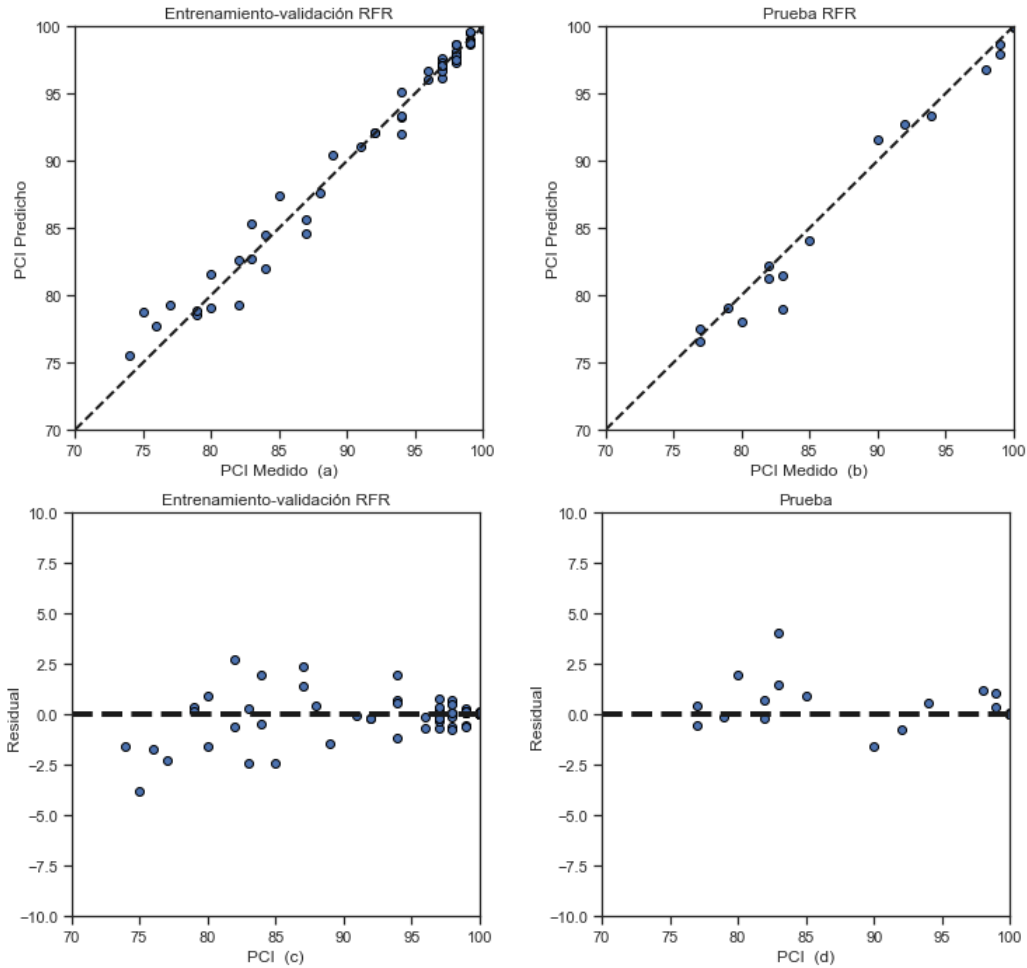


Figura 6.3: Análisis cualitativo de resultados Escenario 3-RFR.

Fuente: Elaboración Propia.

Para ilustrar el uso de los modelos desarrollados, en la Figura 6.4 se muestra las predicciones realizadas para 2 secciones del aeropuerto, pertenecientes a la pista y a la calle de rodaje, en función de los algoritmos utilizados. Cabe señalar que la sección de la pista corresponde a un pavimento con recapado asfáltico construido el año 2006 (PI-1) y la sección de la calle de rodaje a un pavimento convencional construido el año 2010 (RA-1). Por lo demás, la predicción de la curva de desempeño del pavimento en este caso se obtiene mediante un proceso iterativo en que el resultado del modelo se utiliza para predecir el valor de PCI para el año siguiente tomando como referencia el valor de PCI conocido el primer año de evaluación del pavimento 2013, prediciendo valores entre los años 2014 y 2018.




Figura 6.4: Comparación de predicciones para secciones PI-1 Y RA-1, aeropuerto Andrés Sabella.  
Fuente: Elaboración Propia.

En la Figura 6.4 se observa que el algoritmo de RFR es el que presenta mayor similitud a los valores medidos en pistas y calles de rodaje. Por lo demás se tiene que en general los algoritmos tienden a subestimar los valores de PCI. A pesar de ello, esto permitiría tomar decisiones más conservadoras. Por otro lado, el deterioro experimentado por la pista es más acelerado en comparación a calles de rodaje, esto probablemente se deba a la estructuración del pavimento y a factores como la velocidad de operación de las aeronaves.

En cuanto al tiempo empleado por los algoritmos para realizar el proceso de selección de los parámetros óptimos en cada escenario, se obtuvieron los tiempos indicados en la Tabla x. Al respecto, se debe señalar que a pesar de que el algoritmo de ANN toma más tiempo que el resto, no es un tiempo considerable que haga cuestionar su uso, por lo tanto la variable tiempo no es un impedimento para emplear estos algoritmos. Cabe señalar, que los tiempos indicados en la Tabla 6.13, fueron obtenidos en un computador con procesador Intel Core i-5 con 8 gb de ram.

Tabla 6.13: Tiempo de ajuste de algoritmos por escenarios (en segundos).

Escenario	RFR	ANN	DT	SVR
1	13.46	50.92	0.81	1.94
2	14.44	60.05	0.83	2.59
3	17.56	59.9	1.24	1.6

Fuente: Elaboración Propia.

Adicionalmente en la figura 6.5 son contrastados los resultados obtenidos, tanto para pistas y

calles de rodaje de las secciones PI-1 y RA-1, respectivamente; con algunos modelos propuestos en la literatura que ya fueron revisados. Respecto a la Figura 6.5 (a), se observa que la regresión propuesta por PAVEAIR (2021), en términos de tendencia del deterioro es la que más se aproxima al caso de estudio revisado, mientras que el modelo del PMS de Oklahoma es el más conservador. Cabe señalar, que estos modelos son hechos a nivel de red, por lo que son el resultado de un conjunto de datos recogidos de pavimentos diferentes. Sin embargo, en esta sección específica parecen poseer una tendencia similar al deterioro al menos en la zona de pista. En cuanto a la Figura 6.5 (b), se observa que el deterioro de los modelos de la literatura revisados es más acelerado.




Figura 6.5: Comparación resultados modelos de la literatura y propia, secciones de referencia PI-1 y RA-1 de aeropuerto Andrés Sabella.

Fuente: Elaboración Propia.

Para comparar exhaustivamente los modelos mencionados, en la Tabla 8, se hace un análisis cuantitativo del error en base a las métricas R2 y MAE, considerando todas las secciones del aeropuerto y las mediciones de PCI para el periodo 2014-2019. Los resultados indican que el modelo de PAVEAIR (2021) se ajusta al caso de estudio con: R2 de 0.31 y MAE 17.22, para secciones de la pista; mientras que para secciones de las calles de rodaje se obtiene R2 de 0.01 y MAE 14.29. En tanto que el modelo propuesto por Yuan and Mooney (2003) presenta similar precisión en término de las métricas analizadas; por su parte el modelo desarrollado en esta investigación alcanza niveles de precisión superiores, con  $R^2$  de 0.97 y MAE 1.1 para pistas. Cabe señalar que, la baja precisión de estos modelos al ser aplicado al caso de estudio chileno es esperable teniendo en cuenta que son modelos creados para redes de pavimentos y que homologar estos modelos de desempeño de pavimentos al caso chileno es impreciso, en vista de que las causas que originan el deterioro (tránsito, clima, estructura, etc.) son diferentes. En consecuencia, es importante que

las agencias encargadas de la administración de los pavimentos cuenten con una base de datos histórica sobre los pavimentos con el fin de elaborar modelos útiles para la toma de decisiones sobre actividades de M&R con el fin de mantener el estado de los pavimentos.

Tabla 6.14: Análisis de errores de los modelos de la literatura y del modelo propuesto.

Model		MAE	R <sup>2</sup>
Runway	Scenario 3 (RFR)	1.10	0.97
	Yuan & Mooney (2003)	26.97	0.30
	PAVEAIR (2021)	17.22	0.31
Taxiway	Scenario 3 (RFR)	1.53	0.77
	Yuan & Mooney (2003)	22.24	0.01
	PAVEAIR (2021)	14.29	0.01

Fuente: Elaboración propia.

## 6.2 Aplicación Metodología: Nivel de Red

### 6.2.1 Datos de Entrada

En esta segunda parte, se aplican los algoritmos de ML a nivel de red, tomando en cuenta los datos disponibles de toda la red primaria de aeropuertos. Además, dado que las mediciones efectuadas de PCI no presentan una frecuencia de inspección igual en todos los aeropuertos; sumado a la diferencia previsible de los pavimentos en términos de la estructura, calidad de materiales, volumen y frecuencia del tránsito, clima, entre otros; se propone el desarrollo de un modelo de desempeño de pavimentos considerando variables adicionales a las vistas en el modelo a nivel de proyecto, incluyendo por ejemplo variables que midan la variación temporal entre mediciones, el clima y el nivel de operaciones de despegue de los aeropuertos.

En cuanto a la variable asociada al tránsito, se usará una clasificación cualitativa el nivel de operaciones de los aeropuertos (Tabla 4.9), sirviendo de punto de partida para medir el rendimiento del modelo. Otros análisis pueden ser incluidos como cuantificar la distribución lateral del tránsito y el nivel de cargas, sin embargo, inicialmente se recomienda partir con modelos simplificados y en caso de ser necesario incrementar los niveles de precisión del modelo explorar entre algunas cosas agregar otro tipo de variables.

Mientras que en el caso de la variable asociada al clima, se tomará en consideración la clasificación de Koppen revisada en el capítulo 4, de acuerdo a la Tabla 4.10.

Finalmente, para comprender los efectos de la variable climática, de tránsito y PCI en los resultados, se evalúan los siguientes Escenarios:

- **Escenario 4:** Considera tanto los efectos del tránsito, clima y variable asociada al indicador PCI en un estado anterior al de predicción.
- **Escenario 5:** No considera los efectos del clima, pero si los asociados al tránsito y al indicador PCI.
- **Escenario 6:** En este caso si se considera el clima y el indicador PCI, sin embargo, se deja afuera la variable que describe el tránsito aéreo.
- **Escenario 7:** Toma en cuenta, tanto las variables asociada a clima y tránsito, pero no una variable asociada al indicador PCI en un estado anterior. Esto permite analizar la influencia en los resultados de la variable PCI.

El resto de variables asociadas al uso (rama), tipo de pavimento, edad, entre otras. Se considera por igual en todos los modelos. La Tabla 6.15, presenta los escenario analizados y las variables usadas en cada caso.

Tabla 6.15: Descripción de variables y escenarios usados (Nivel de Red).

Variable	Descripción	Escenario			
		4	5	6	7
Rama	Una parte identificable de la red que tiene una función específica.	x	x	x	x
Tipo Pavimento	Pavimento Convencional o Recapado.	x	x	x	x
Edad	Antigüedad del pavimento desde el año de construcción o rehabilitación (año).	x	x	x	x
Espesor	Espesor superficial del pavimento (cm).	x	x	x	x
PCI	PCI actual	x	x	x	
$\Delta t$	Variación temporal en años entre la medición actual y el año a predecir.	x	x	x	x
Nivel Operaciones	Nivel cualitativo de operaciones según a tabla 4.9.	x	x		x
Clima	Tipo de clima según clasificación de Koppen, tabla 4.10.	x		x	x

Fuente: Elaboración propia.

En el Anexo F, se muestra la base de datos utilizada.

## 6.2.2 Procesamiento de datos

En esta sección los datos, al igual que en el procesamiento de datos para el modelo a nivel de proyecto, se deberá tabular en primer lugar los datos de acuerdo a la clasificación climatológica y

de operaciones señaladas en las Tablas 4.9 y 4.10.

La siguiente etapa corresponde a la limpieza de datos, para ello se considera como criterio base que ninguna sección recibirá algún tratamiento de mantenimiento, eliminando aquellos datos que experimenten un incremento en la condición del pavimento respecto al estado conocido anterior. Ver Tabla 6.16, que ejemplifica la limpieza de datos con acciones de mantenimiento. Por lo demás, cabe señalar que a diferencia del análisis a nivel de proyecto en la que las cantidad de datos era reducida y se aceptaba un margen de error de  $\pm 5$  puntos de PCI entre las mediciones, en este caso no se acepta dicho criterio.

Tabla 6.16: Ejemplo limpieza de datos, eliminando datos que experimenten incremento en la condición de PCI.

	Aeropuerto	Sección	PCI 2013	PCI 2014	PCI 2015	PCI 2016	PCI 2017	PCI 2018	PCI 2019	PCI 2020	PCI 2021
Antes	Andrés Sabella	DB-1	99	97	97	96	97	98	97	97	93
	Andrés Sabella	DC-1	95	94	92	91	94	94	92	92	92
	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.
Después	Andrés Sabella	DB-1	99	97	97	96	-	-	-	-	93
	Andrés Sabella	DC-1	95	94	92	91	-	-	-	-	-
	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.

Fuente: Elaboración propia.

Otro aspecto a considerar en la limpieza de datos corresponde a la eliminación de aquellos datos que de acuerdo a su clasificación cualitativa no se encuentren en una cantidad significativa. En este caso mediante un análisis visual se eliminan progresivamente los siguientes datos: Secciones pertenecientes a clima Templado con lluvias principalmente en invierno, ver Figura 6.6; Secciones asociadas a un tránsito de tipo medio, ver Figura 6.7 ; secciones de hormigón, ver Figura 6.8; y finalmente, estructuras de pavimentos tipo Mixta o Sandwich , Figura 6.9.




Figura 6.6: Distribución de datos según zona climática.  
Fuente: Elaboración Propia.




Figura 6.7: Distribución de datos según nivel de operaciones, según Tabla4.9.  
Fuente: Elaboración Propia.




Figura 6.8: Distribución de datos según tipo de superficie de pavimento.  
Fuente: Elaboración Propia.




Figura 6.9: Distribución de datos según tipo de pavimento (convencional, recapado, mixta o mixta).  
Fuente: Elaboración Propia.

En cuanto a la formulación del modelo se escoge una de tipo dinámico, para los escenarios 4, 5 y 6. Es decir, que la variable a predecir depende de una variable de entrada en un estado anterior de la misma. Para ello, se procede a ordenar los datos de manera temporal en función de la variable PCI. En efecto se crean ejemplos formado por la variable PCI en un tiempo  $t-n\dots t-3$ ,  $t-2$  y  $t-1$ , según corresponda. La Tabla 6.17, ejemplifica lo enunciado.

Tabla 6.17: Extracto base de datos, para análisis a nivel de red.

Aeropuerto	Sección Característica	Año Evaluación	Año Predicción	Variables de Entrada								Variable Salida
				PCI t- $\Delta t$	Ubicación	Espesor	Edad Pavimento	Tipo Pavimento	clima	transito	Deta t	PCI t
Chacalluta	DC-1	2014	2016	81	Otros Rodajes	10	9	Convencional	Seco-Árido	Bajo	2	80
Chacalluta	DC-1	2016	2021	80	Otros Rodajes	10	11	Convencional	Seco-Árido	Bajo	5	74
Chacalluta	DC-1	2014	2021	81	Otros Rodajes	10	9	Convencional	Seco-Árido	Bajo	7	74
.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.
Chacalluta	DB-1	2014	2016	95	Otros Rodajes	10	9	Convencional	Seco-Árido	Bajo	2	92
Chacalluta	DB-1	2016	2021	92	Otros Rodajes	10	11	Convencional	Seco-Árido	Bajo	5	84
Chacalluta	DB-1	2014	2021	95	Otros Rodajes	10	9	Convencional	Seco-Árido	Bajo	7	84

Fuente: Elaboración propia.

El siguiente paso corresponde a escalar las variables numéricas y binarizar aquellas de tipo cualitativo, usando las funciones de Scikit Learn One Hot-Encoder. En este caso la Tabla 6.18, ejemplifica la binarización y escalado de variables para el Escenario 4.

Tabla 6.18: Ejemplo escalamiento de variables y transformación datos cualitativos para Escenario 4.

PCI $\Delta$	Espesor	Edad Pavimento	$\Delta t$	Ubicación_ Otros Rodajes	Ubicación_ Pista	Ubicación_ Plataforma	Ubicación_ Rodaje Paralelo	Tipo Pavimento_ Recapado	Clima_Templado - Lluvias todo el año	Transito_ Medio Alto
0.22	-0.34	0.31	-0.59	0	0	0	1	0	0	1
-1.92	5.22	0.31	-0.59	0	0	0	1	0	0	0
-0.99	1.89	0.31	-1.12	0	1	0	0	1	0	1
-1.39	-2.19	3.29	-0.07	0	0	0	0	0	0	0
.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.
-0.85	-0.34	2.44	0.45	0	0	1	0	0	0	0

Fuente: Elaboración propia.

Finalmente los datos son divididos en conjuntos de entrenamiento-validación y prueba, en una proporción de 80% y 20% respectivamente. Una descripción estadística de los conjuntos de entrenamiento y prueba se presentan en la Tabla 6.19.

Tabla 6.19: Descripción de datos cuantitativos para conjunto de entrenamiento y prueba.

	PCI		Espesor		Edad Pavimento		$\Delta t$	
	Entr.-val.	Prueba	Entr.-val.	Prueba	Entr.-val.	Prueba	Entr.-val.	Prueba
# Datos	402	101	402	101	402	101	402	101
Promedio	95.4	95	10.9	10.9	7.6	7.2	3.1	2.7
Desviación Estándar	7.5	7.5	2.7	2.6	4.7	4.3	1.9	1.8
min	45	72	5	5	0	0	1	1
25%	94	94	10	10	4	4	1	1
50%	99	99	10	10	7	7	3	2
75%	100	100	11	11	9.75	9	5	4
max	100	100	25	23	26	23	8	8

Fuente: Elaboración propia.

### 6.2.3 Configuración variables y algoritmos

En esta parte, se emplean los conceptos usados con anterioridad: RFECV, para selección óptima de variables en cada escenario, usando el algoritmo base Random Forest con validación cruzada de 5 pliegues; y Grid Search de Scikit learn , para elección correcta de hiperparámetros de los algoritmos usados.

Al respecto, la Figura 6.10 , muestra que la cantidad óptima de variables para los escenarios 4, 5 y 6 es 8 variables, mientras que para el escenario 7, solo son necesarias 2 variables. Además, la Tabla 6.20 muestra el nivel de importancia de las variables asociadas en cada caso. Observando que en los casos 4,5 y 6 las variables de mayor influencia son: PCI ( $\geq 75.1\%$  ), Espesor ( $\geq 6.9\%$ ),  $\Delta t$  ( $\geq 6.2\%$ ) y Edad ( $\geq 6.0\%$ ). Mientras que para el caso 7, el espesor y la edad del pavimento, poseen un 57.5 % y 42.5% de importancia, respectivamente.




Figura 6.10: Elección de características según RFECV, nivel de red.

Fuente: Elaboración Propia.

Tabla 6.20: Nivel de importancia de variables análisis nivel de red.

Escenario	Variable	importancia %	Escenario	Variable	importancia %
4	PCI actual	75.1	6	PCI actual	75.1
	Espesor	6.9		Espesor	6.9
	Edad Pavimento	6.2		Edad Pavimento	6.2
	$\Delta t$	6.2		$\Delta t$	6.2
	Clima_Templado-Lluvias todo el año	2.7		clima_Templado-Lluvias todo el año	2.7
	Ubicación_Pista	1.2		Ubicación_Pista	1.2
	Ubicación_Otros Rodajes	0.9		Ubicación_Otros Rodajes	0.9
	Tipo Pavimento_Recapado	0.8		Tipo Pavimento_Recapado	0.8
5	PCI actual	76.9	7	Espesor	57.5
	Espesor	7.5		Edad Pavimento	42.5
	$\Delta t$	6.2			
	Edad Pavimento	6.0			
	Ubicación_Pista	1.2			
	Ubicación_Otros Rodajes	0.9			
	transito_Medio Alto	0.7			
	Tipo Pavimento_Recapado	0.6			

Fuente: Elaboración Propia.

Usando Grid Search de Scikit Learn y a partir de una lista de hiperparámetros previamente seleccionadas, se obtienen los valores óptimos de hiperparámetros en cada uno de los Escenario y algoritmos usados. Ver Tabla 6.21 con lo indicado. Cabe señalar, que de acuerdo a los resultados obtenidos, se observa que todos los Escenarios poseen igual hiperparámetros en el caso de los algoritmos RFR y SVM, existiendo diferencia con el Escenario 7 en los algoritmos de ANN y DTR.

Tabla 6.21: Niveles de Importancia de variables según Escenario en estudio.

Algoritmo	Hiperparámetros	Hiperparámetros Probados	Hiperparámetros Seleccionados			
			Escenario 4	Escenario 5	Escenario 6	Escenario 7
ANN	Capas Ocultas (Cantidad Neuronas)	[(10, ), (10, 10), (10, 10, 10)]	(10,)	(10,)	(10,)	(10,10)
	Función Activation	[ <i>relu, logistic</i> ]	relu	relu	relu	relu
	alpha	[0.0001, 0.05, 5, 50, 75, 100, 500]	5	5	5	0.05
RFR	Prof. Máxima del Árbol	[1, 2, 4, 6]	6	6	6	6
	El número de características a considerar cuando se busca la mejor división.	[ <i>auto, sqrt, log2</i> ]	auto	auto	auto	auto
SVM	Kernel	[ <i>rbf, linear, poly</i> ]	rbf	rbf	rbf	rbf
	C	[0.1, 1, 10, 100]	100	100	100	100
DTR	Prof. Máxima del Árbol	[1, 2, 4, 6]	6	6	6	6
	Número mínimo de muestras necesarias para dividir un nodo interno	[1, 2, 4, 6]	1	1	1	1
	Número mínimo de muestras necesarias para estar en un nodo hoja.	[1, 2, 4, 6]	2	2	2	6

Fuente: Elaboración Propia.

## 6.2.4 Entrenamiento y Evaluación de Modelos

En esta etapa, se procede a entrenar, validar y testear los modelos generados. Para ello se entrena y validan modelos usando subconjuntos de datos generados aleatoriamente mediante validación cruzada de 5 pliegues con 20 repeticiones. El resultado de los algoritmos ensayados en cada escenario, se indican en la Tabla 6.22.

Tabla 6.22: Evaluación cuantitativa de resultados en etapa entrenamiento-validación, según Escenarios 4, 5, 6 y 7.

Escenario	Algoritmo	AVG R2 (STD)		AVG MAE (STD)		AVG MSE (STD)	
		Entrenamiento	Validación	Entrenamiento	Validación	Entrenamiento	Validación
4	ANN	0.85 (0.02)	0.81 (0.07)	2.57 (0.10)	2.79 (0.30)	4.17 (0.69)	3.80 (0.18)
	RFR	0.96 (0.00)	0.84 (0.08)	1.41 (0.05)	2.27 (0.34)	3.84 (0.88)	2.06 (0.1)
	SVM	0.94 (0.01)	0.81 (0.05)	1.12 (0.08)	2.24 (0.39)	4.25 (0.86)	2.40 (0.16)
	DTR	0.96 (0.00)	0.77 (0.11)	1.35 (0.08)	2.55 (0.45)	4.51 (1.16)	1.99 (0.13)
5	ANN	0.86 (0.02)	0.82 (0.06)	2.56 (0.13)	2.78 (0.28)	4.08 (0.58)	3.74 (0.02)
	RFR	0.96 (0.01)	0.84 (0.08)	1.39 (0.06)	2.23 (0.32)	3.76 (0.86)	2.04 (0.1)
	SVM	0.95 (0.01)	0.82 (0.05)	1.05 (0.07)	2.18 (0.36)	4.10 (0.81)	2.26 (0.17)
	DTR	0.96 (0.00)	0.78 (0.11)	1.34 (0.07)	2.55 (0.45)	4.46 (1.13)	1.99 (0.13)
6	ANN	0.85 (0.01)	0.81 (0.06)	2.57 (0.11)	2.80 (0.31)	4.18 (0.67)	3.81 (0.16)
	RFR	0.96 (0.00)	0.83 (0.08)	1.41 (0.05)	2.27 (0.33)	3.85 (0.88)	2.06 (0.09)
	SVM	0.94 (0.01)	0.81 (0.05)	1.12 (0.08)	2.54 (0.41)	4.53 (1.13)	1.99 (0.13)
	DTR	0.96 (0.00)	0.77 (0.12)	1.35 (0.08)	2.54 (0.41)	4.53 (1.13)	1.99 (0.13)
7	ANN	0.56 (0.05)	0.48 (0.13)	4.54 (0.46)	4.74 (0.69)	6.98 (1.08)	6.57 (0.41)
	RFR	0.75 (0.02)	0.57 (0.09)	3.5 (0.12)	4.13 (0.48)	6.36 (0.92)	5.01 (0.17)
	SVM	0.63 (0.03)	0.46 (0.12)	3.49 (0.13)	4.23 (0.55)	7.14 (1.22)	6.02 (0.29)
	DTR	0.74 (0.02)	0.52 (0.11)	3.53 (0.12)	4.18 (0.52)	6.74 (1.19)	5.11 (0.18)

Fuente: Elaboración propia.

En la Tabla 6.22, se observa en términos generales que el algoritmo de mejor desempeño en los escenarios 4, 5 y 6 es RFR con  $AVG R^2 \geq 0.96$  y  $AVG R^2 \geq 0.83(0.08)$  para entrenamiento y validación, respectivamente. En tanto que, en el escenario 7 se observa una diferencia notoria en términos del error medido, con un desempeño más bajo alcanzando un valor de  $AVG R^2 = 0.75$ . Respecto a los otros errores, se observa una tendencia similar  $R^2$  sobresaliendo RFR.

Por otro lado, para validar la capacidad de generalización de los modelos, los resultados son probados en un subconjunto de datos no vistos en las etapas de entrenamiento. En efecto, la Tabla 6.23 presenta los resultados en el conjunto de prueba.

Tabla 6.23: Resultados etapa de prueba, para modelos de desempeño de pavimentos a nivel de red.

Algoritmo	Escenario 4			Escenario 5			Escenario 6			Escenario 7		
	R2	MAE	MSE	R2	MAE	MSE	R2	MAE	MSE	R2	MAE	MSE
ANN	0.90	2.02	9.6	0.90	2.11	9.03	0.90	2.02	9.60	0.41	5.44	54.40
RFR	0.90	1.80	8.85	0.92	1.72	7.66	0.92	1.75	7.07	0.48	4.65	48.18
SVM	0.87	2.03	11.63	0.89	1.82	10.25	0.87	2.03	11.63	0.41	4.53	54.62
DTR	0.87	2.32	14.02	0.85	2.32	14.02	0.87	2.25	12.15	0.44	4.90	51.64

Fuente: Elaboración propia.

Al respecto, se observa que el mejor rendimiento lo posee el algoritmo RFR. No obstante, se aprecia cierta similitud en los resultados de los escenarios 4, 5 y 6 que hace complejo escoger uno sobre otro, a diferencia del escenario 7 que es descartado categóricamente con  $R^2 \leq 0.44$ . En este último, hay evidencia clara de experimentar Underfitting con  $AVG R^2 = 0.75$  (RFR) en etapa de entrenamiento y  $R^2 = 0.48$  (RFR) en etapa de prueba. En general, esto se produce debido a que no hay suficientes variables o el modelo no tiene la complejidad suficiente para modelar adecuadamente los datos. Asimismo, se comprueba que el indicador PCI en un estado anterior a la condición que se quiere predecir mejora notoriamente los resultados observable en el escenario 4.

Para verificar si existen diferencias reales o es una mera casualidad estadística entre los Escenarios, se hace uso de test de Hipótesis usando los errores medidos de las 20 repeticiones de la validación cruzada en etapa de entrenamiento y validación cruzada. Los test de hipótesis usados en este caso corresponden a: t-student para muestras que se distribuyen normal; y Mann Whitney para el otro caso. En efecto a continuación se define la hipótesis nula y alternativa del problema señalado:

- Hipótesis Nula:  $H_0 = \mu_1 = \mu_2$ , donde  $\mu_1$  y  $\mu_2$  son las medias del error en términos de MAE de cada grupo de evaluación.
- Hipótesis Alternativa,  $H_1 : \mu_1 \neq \mu_2$ .
- La Hipótesis nula, es rechazada cuando el valor de  $p \leq 0.05$

En consecuencia La Tabla 6.24, muestra los resultados de aplicar los resultados de test de hipótesis correspondientes, tomando como referencia el escenario 4, que incluye variables asociadas al tránsito y clima, que son de interés.

Tabla 6.24: Resultados test de hipótesis, a nivel de red.

$\mu_1$	$\mu_2$	Ho	Test	Varianzas	p-value
AVG MAE (Escenario 4-RFR)	AVG MAE (Escenario 5-RFR)	Aceptada	t-student	iguales	9.272e-02
AVG MAE (Escenario 4-RFR)	AVG MAE (Escenario 6-RFR)	Aceptada	Mann whitney	-	3.93e-01
AVG MAE (Escenario 4-RFR)	AVG MAE (Escenario 7-RFR)	Rechazada	t-student	iguales	3.14e-46

Fuente: Elaboración Propia.

En cuanto a los resultados obtenidos de 6.24 , se destaca que la media del error medido (MAE) para los escenarios 4, 5 y 6 son iguales. Ahora bien, dada la naturaleza del problema y a que no se puede desconocer la relevancia del clima y tránsito en los efectos del pavimento, y pensando que la base de datos pueda ser actualizada y considerar datos de naturaleza diferente (clima y nivel de tránsito), en este caso se recomienda el escenario 4 para su uso. En tanto que, los resultados del test de hipótesis para el escenario 7 indica que se rechaza la igualdad en las medias del error MAE con el escenario 4.

Por otro lado, la Figura 6.11 indica mediante gráfico de dispersión las diferencias encontradas en términos de los valores medidos y predichos. Los gráficos (a) y (b) muestran una tendencia de los datos ubicarse en la línea de 45°, en consistencia con los resultados anteriores. En tanto que para los gráficos (c) y (d) se observa que el patrón del error es aleatorio, sin embargo, existen errores en la predicción de hasta 10 PCI. Ahora bien estos son errores aislados y cuyos datos de origen pueden eliminarse para incrementar la precisión. No obstante, estos datos no fueron dejados afuera en este informe.

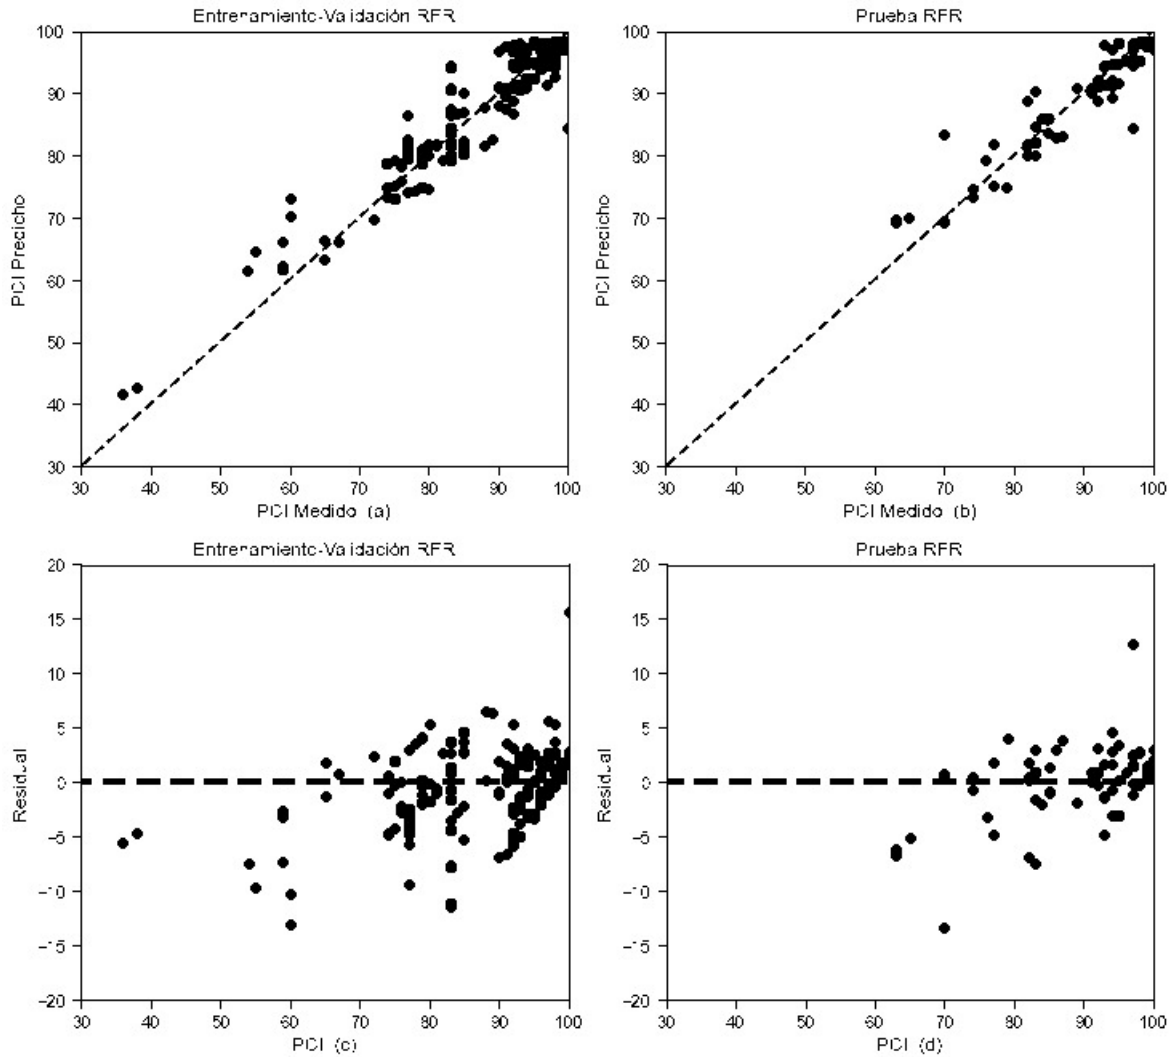


Figura 6.11: Análisis cualitativo de resultados Escenario 4 usando RFR, para análisis nivel de red.  
Fuente: Elaboración Propia.

Con el objeto de ilustrar la capacidad de predicción del modelo de desempeño de pavimentos, la Figura 6.12 contrasta los resultados medidos versus los valores predichos obtenidos iterativamente a partir del primer valor registrado para cada sección en particular del aeropuerto Andrés Sabella.

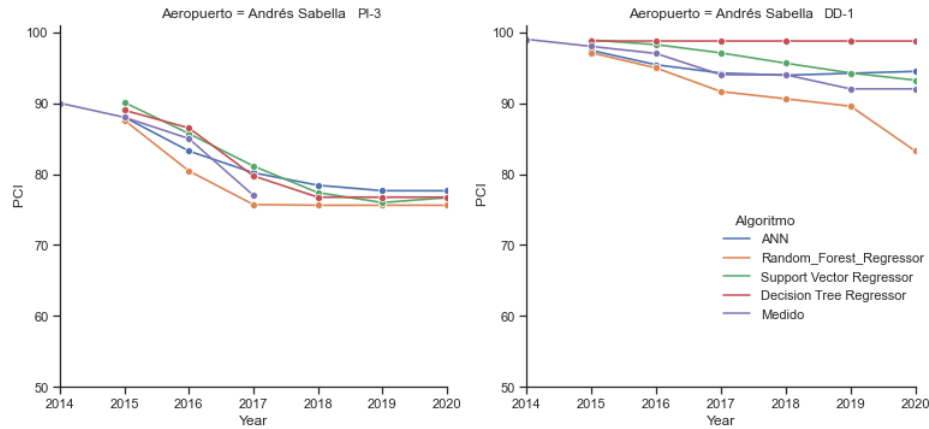


Figura 6.12: Comparación resultados medidos y predichos para secciones PI-3 y DD-1, aeropuerto Andrés Sabella.

Fuente: Elaboración Propia.

Los resultados de la Figura 6.12, indican que los modelos de desempeño elaborados capturan correctamente la tendencia del deterioro del pavimento, quedando validado además mediante un análisis cuantitativo y cualitativo del error, hecho en pasos anteriores.

Asimismo, se realizó una comparación del tiempo tomado por los algoritmos para ajustarse a los datos en cada escenario obtenido en la Tabla 6.25. Al respecto, es importante señalar que el tiempo no significa una condicionante para aplicar dichos algoritmos en vista de los resultados obtenidos. Es importante mencionar que estos resultados fueron obtenidos en un computador procesador Intel Core 5, de 8 gb de ram.

Tabla 6.25: Tiempo de ajuste de algoritmos en escenario 4 a 8.

Escenario	RFR	ANN	DT	SVR
4	61.21	133.04	14.33	8.61
5	59.84	124.63	15.85	8.76
6	59.25	113.14	15.47	10.00
7	62.56	102.09	13,09	6,20

Fuente: Elaboración Propia.

Adicionalmente de la Figura 6.16 a la Figura 6.18 se indican algunas proyecciones de PCI hechas entre el período 2020 a 2030. Cabe señalar, que estas predicciones fueron hechas a partir del primer dato conocido, manteniendo la variación temporal  $\Delta t$  de la que se tenía registro en las mediciones previas para cada sección. Respecto a las figuras mencionadas, se observa una tendencia de deterioro diferente por aeropuerto, obteniendo por ejemplo en el aeropuerto de La Araucanía un decaimiento de la condición en 3 fases en contraste a una disminución un tanto uniforme para

algunas secciones del aeropuerto Balmaceda (Figura ) y en 2 fases para el aeropuerto Desierto de Atacama. Ahora bien, se debe tener precaución respecto al uso de estas predicciones tomando en consideración que las predicciones son hechas con valores fuera del rango de entrenamiento, por ejemplo la edad del pavimento supera los 26 años, valor máximo registrado en la base de datos del modelo. Ahora bien, con el ingreso de nuevos datos es posible incrementar los niveles de confiabilidad en los modelos para rangos más amplios que ayuden a la toma de decisiones de manera más objetiva y así más oportuna.

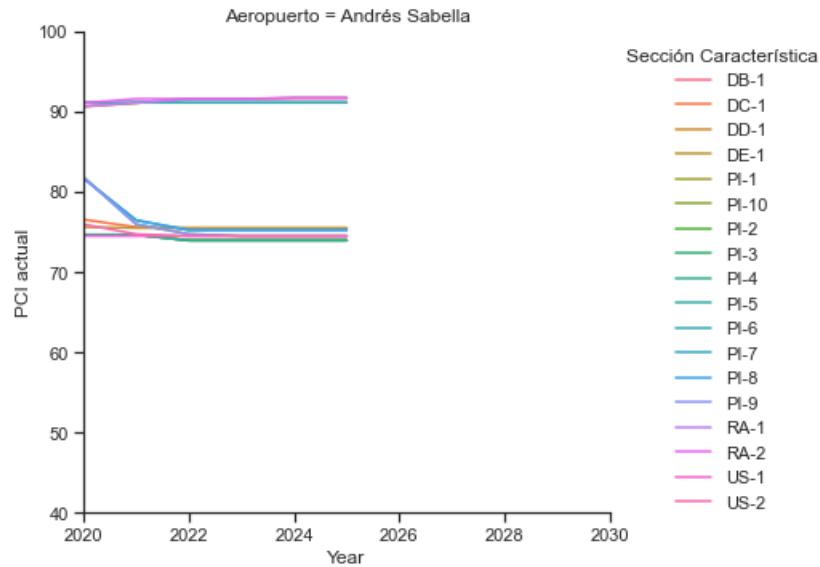


Figura 6.13: Proyecciones PCI 2020-2025 para aeropuerto Andrés Sabella, usando RFR y variables Escenario 4.

Fuente: Elaboración Propia.




Figura 6.14: Proyecciones PCI 2020-2030 para aeropuerto La Florida, usando RFR y variables Escenario 4.

Fuente: Elaboración Propia.




Figura 6.15: Proyecciones PCI 2020-2025 para aeropuerto Desierto de Aacama, usando RFR y variables Escenario 4.

Fuente: Elaboración Propia.




Figura 6.16: Proyecciones PCI 2020-2030 para aeropuerto Balmaceda, usando RFR y variables Escenario 4.

Fuente: Elaboración Propia.

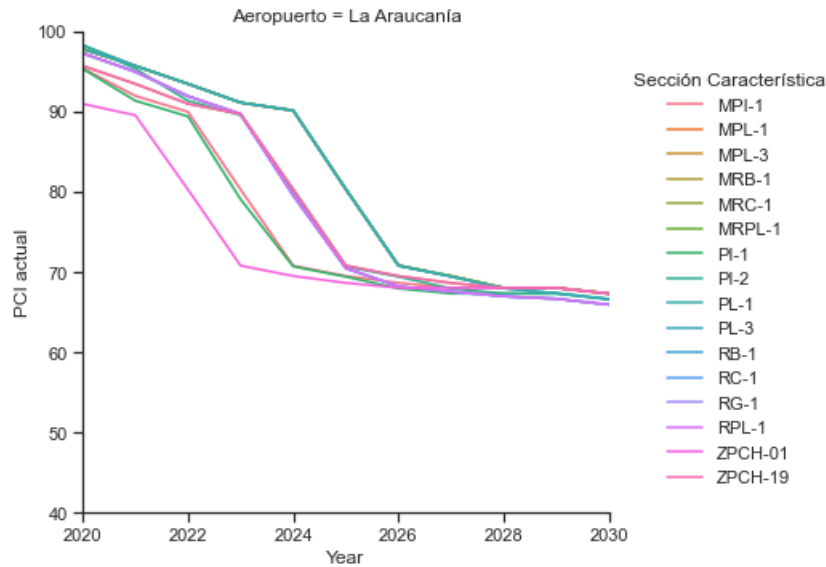


Figura 6.17: Proyecciones PCI 2020-2030 para aeropuerto La Araucanía, usando RFR y variables Escenario 4.

Fuente: Elaboración Propia.




Figura 6.18: Proyecciones PCI 2020-2030 para aeropuerto Presidente Carlos Ibáñez del Campo, usando RFR y variables Escenario 4.

Fuente: Elaboración Propia.

En un esfuerzo adicional, con el objeto de comparar los resultados obtenidos usando ML se realiza un análisis de regresión con los datos usados para llevar a cabo el análisis a nivel de red. Para ello se considera el concepto de familia de pavimento, agrupando los datos y haciendo regresiones sobre estos de acuerdo a la ubicación de la sección, la clasificación de clima y tránsito.

Las variables usadas en estos grupos corresponden a la edad del pavimento (variable independiente) y el valor de PCI (variable dependiente). En tanto que, un análisis de regresión fue hecho con polinomios de diferente grados (1 a 5) por cada familia de pavimento formada, escogiendo el grado polinómico por familia mediante un análisis de las métricas  $R^2$  en etapa de entrenamiento y prueba, seleccionando en tal caso el grado polinomial que minimiza la diferencias entre las métricas señaladas y que maximiza el valor de  $R^2$ . La Figura 6.19, ejemplifica lo antes señalado para algunas familia de pavimentos formadas.




Figura 6.19: Ejemplo análisis de sensibilidad en base a grado de polinomio.  
Fuente: Elaboración Propia.

Es importante señalar, que los modelos fueron ajustado en base a una condición extra, que busca que el polinomio sea estrictamente decreciente (pendiente negativa), que va de la mano con el fenómeno de deterioro de un pavimento sin acciones de mantenimiento que eleven la condición del pavimento. La Figura 6.20, ejemplifica lo señalado a partir de un ajuste de grado 2 a la familia de pavimentos formada por los datos de margen y zona de protección al chorro con nivel de operaciones bajo.




Figura 6.20: Análisis de regresión con polinomio de grado 1 a 3.  
Fuente: Elaboración Propia.

En tanto que la Tabla 6.26, recoge las regresiones calculadas que mostraron tener mejor desempeño con validación simple usando un conjunto de entrenamiento y otro de prueba, distribuidos aleatoriamente con Scikit learn , usando un estado aleatorio inicial con *random\_state* = 100. Para mayor detalle sobre el análisis de regresión hecho, consultar anexo G con análisis de residuos, en la que no se satisfacen las condiciones de normalidad, por lo que el uso de intervalos de confianza no son fiables.

Tabla 6.26: Compendio regresiones por familia de pavimento.

Nombre	Datos	Grado Reg.	$R^2$ Entren.	$R^2$ Prueba	MSE Entren.	MSE Prueba	a0	a1	a2	a3	a4	a5
Pista-Templado-Lluvias todo el año-Bajo	13	4	0.81	0.61	53.78	23.57	100.340429	4.49E-17	-0.642206	0.087034	-0.003317	
Pista-Bajo	28	5	0.70	0.75	42,21	24,31	100,046886	-3,197422	1,067521	-0,170427	0,012925	-0,000375
Plataforma-Seco-Árido	25	4	0,63	0,62	10,12	3,39	98,974594	-1,359312	0,205933	-0,011743	0,000152	

Fuente: Elaboración Propia.

Para ilustrar sobre los resultados obtenidos en la Tabla 6.26, la Figura 6.21 muestra los valores medidos y las regresiones obtenidas con lo modelo señalados.

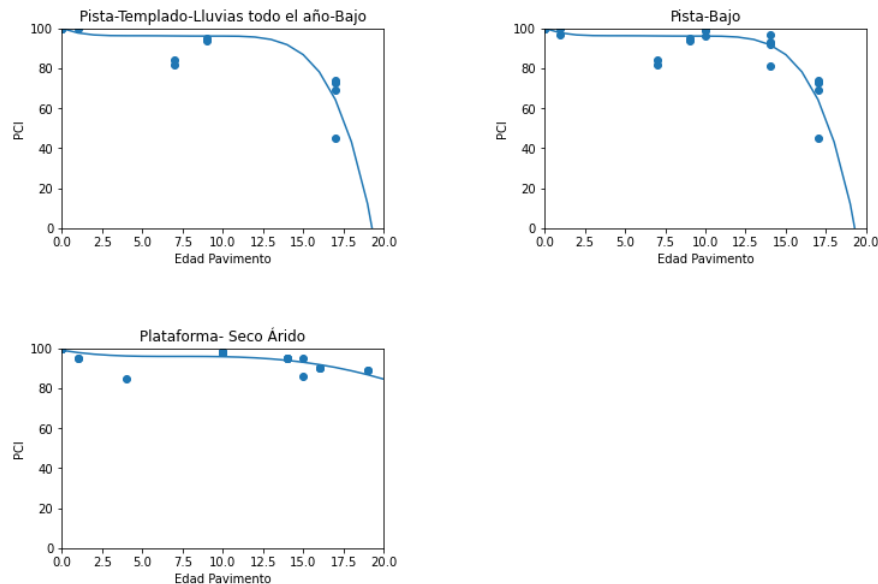


Figura 6.21: Regresiones señaladas en tabla 6.26.

Fuente: Elaboración Propia.

Respecto a los valores obtenidos mediante regresión polinómica es preciso señalar:

- La complejidad de los modelos de ML, evidentemente superan el uso de regresiones lineales. No obstante, los datos utilizados para el calculo de los diferentes modelos no son equivalentes. Por este motivo, a pesar de que los niveles de precisión alcanzados usando regresión no son altos en comparación a ML, en condiciones que no se dispone de suficientes datos pueden ser incluso mejor que herramientas de ML.
- El uso de regresiones, implica agrupar datos con características similares, en cuyo caso significa significa una disminución progresiva de los datos con los que trabajar. Esto puede convertirse en un problema cuando la cantidad de datos es reducida. No obstante, usar ML no supone disminuir los ejemplos de entrenamiento siempre y cuando la clases se encuentren balanceadas, es decir, las características de los datos estén bien distribuidas.
- El uso de regresiones lineales, en la literatura es frecuente. No obstante a diferencia de los problemas revisados, en este caso la cantidad de datos para modelar es baja y los niveles de precisión no son suficientes. En consecuencia, se recomienda su uso en la medida que se obtengan más datos. En la misma línea, a pesar de que los niveles de precisión alcanzados usando ML son elevados, se debe tener precaución sobre su uso respetando los rangos de valores de las variables usadas.
- Es importante señalar que aún cuando los resultados usando regresión lineal son poco satisfactorios, se pueden explorar otros tipos de regresiones multi lineales, considerando características adicionales como por ejemplo, la condición previa del pavimento que al menos usando algoritmos de ML significo una mejora significativa en los resultados.

# Capítulo 7

## Conclusiones, recomendaciones y futuras líneas de investigación

En este trabajo se formuló una metodología para elaborar modelos de desempeño de pavimentos aeroportuarios chilenos usando algoritmos de ML. Validando dicha metodología con una aplicación a nivel de proyecto, en base a los datos del aeropuerto Andrés Sabella; y a una aplicación a nivel de Red con datos de la Red Primaria de aeropuertos de Chile. Los resultados de estas aplicaciones fueron exitoso demostrando la alta capacidad de las técnicas de ML para predecir la condición de los pavimentos aeroportuarios, demostrando la hipótesis planteada junto con el cumplimiento de los objetivos principales de esta investigación. Asimismo, este trabajo se enmarcó en el convenio de colaboración entre la universidad Técnica Federico Santa María y la Dirección de Aeropuertos del Ministerio de Obras Públicas, que busca potenciar el desarrollo del sistema de gestión aeroportuario del país.

### 7.0.1 Conclusiones de los objetivos de la investigación

Las conclusiones obtenidas de esta investigación de acuerdo a los objetivos específicos se detallan a continuación.

#### **Objetivo específico 1**

Una revisión profunda de la literatura evidenció el incremento del uso de técnicas de ML en la elaboración de modelos de desempeño de pavimentos en la última década. Destacándose por la capacidad de trabajar con grandes bases de datos; su eficiencia en problemas de altas dimensiones, que incluyen varias variables a la vez como el clima, tráfico, información estructural, edad, entre otros; la alta capacidad de predicción demostrada en diferentes publicaciones sobre

técnicas clásicas de regresión; la capacidad de actualización de los modelos en tiempo real. No obstante, las desventajas son el uso de grandes cantidades de datos y que en lo posible se incluyan múltiples estados y características para modelar el fenómeno de deterioro de los pavimentos; por otro lado, se debe tener en consideración que su aplicación requiere conocimiento especializado sobre el tema lo que implica invertir un tiempo razonable de estudio.

Entre los algoritmos más usados se identificó el uso de ANN, seguido en una proporción menor de RFR, DT y SVM. Determinándose que cuando la interpretabilidad de los modelos no cumple un rol clave, el uso de estos algoritmos es altamente recomendable, como así también en problemas que requieren una actualización constante de la base de datos.

### **Objetivo específico 2**

En base a una revisión exhaustiva de informes sobre el estado de los pavimentos de aeropuertos de la Red Primaria, se elaboró un catastro de datos identificando las variables medidas y la cantidad de ellos disponible. Al respecto se obtuvo que los datos referentes al comportamiento estructural como los módulos de elasticidad de la estructura, encuentra disponible solo para una cantidad acotada de aeropuertos de la red, por ende su uso no es recomendable. Otros indicadores como rugosidad, fricción se descartan de igual forma. Respecto al índice PCI, se observan diferencias en la frecuencia de inspección entre los aeropuertos como de las ramas evaluadas. Al respecto, se recomendó que la inspección no supere los 3 años, según la experiencia internacional.

### **Objetivo específico 3**

Se definió una metodología para elaborar modelos de desempeño de aeropuertos usando ML. Recomendando variables a usar en base a referencias de la literatura y a los antecedentes recopilados sobre la base de datos disponible. Adicionalmente, se especificaron los procedimientos para procesar datos y aplicar algoritmos de ML en la predicción de la condición del pavimento. Para la evaluación de los modelos se propuso un análisis cualitativo y cuantitativo.

### **Objetivo específico 4**

La metodología propuesta, fue aplicada a nivel de proyecto y a nivel de red, con resultados satisfactorios. A su vez, diferentes escenarios fueron evaluados escogiendo los de mejor desempeño en cada caso. Cabe señalar que, 4 algoritmos de ML se usaron y comparados en términos cuantitativos y cualitativos, sobresaliendo entre ellos el algoritmo RFR.

## **7.0.2 Conclusiones de la investigación**

Por otro lado, a continuación se indican las conclusiones derivadas de los resultados de aplicar la metodología a nivel de proyecto y a nivel de Red para 7 escenarios revisados. Definidos para

el análisis a nivel de proyecto los escenarios 1 a 3, diferenciados principalmente por la variable asociada al tránsito. En tanto que para nivel de red 4 escenarios se definieron (4 a 7), incluyendo variables asociadas al clima y a una clasificación del tránsito de acuerdo al nivel de operaciones de los aeropuertos, excluyendo en el escenario 7 la variable PCI en un estado anterior al nivel de predicción que fue considerado en todos los escenarios. Concluyendo :

- Que para los datos analizados el algoritmo de RFR superior a ANN, SVR y DTR en los escenarios 1, 2 y 3 con  $R^2 > 0.97$  y  $MAE < 2.01$ , a nivel de proyecto. En tanto que, a nivel de Red para los escenarios 4, 5 y 6 usando RFR se obtuvo  $R^2 > 0.9$  y  $MAE < 1.9$ ; mientras que, en el escenario 7 se obtuvo un desempeño notoriamente menor con  $R^2 = 0.48$  y  $MAE = 4.65$ , en efecto se concluye que el uso de una variable asociada a la condición que se quiere predecir aumenta la precisión de los modelos de desempeño.
- Que para los escenarios 1, 2 y 3 , no existen diferencias estadísticas en términos del error medio MAE en los escenarios revisados, validado mediante un análisis de hipótesis. En consecuencia, se recomienda usar un modelo simple que no toma en cuenta la variable asociada al tránsito para los datos analizados.
- Que respecto al análisis de los escenarios 4 a 7, se obtiene mediante test de hipótesis la igualdad de los escenarios 4, 5 y 6, en términos de error medio medido con la métrica MAE. Recomendando en este caso el uso del Escenario 4, dado que incluye variables asociada a tránsito y clima que explican el deterioro del pavimento.
- Que a nivel de red un análisis adicional fue hecho, empleado regresiones polinómicas sujetas a restricción de pendiente del tipo monótonamente decreciente. Los resultados, mostraron que los niveles de precisión alcanzan dos disminuyo notoriamente respecto a ML. No obstante, no son comparables directamente dado que la cantidad de datos usados en cada caso se redujo al emplear el concepto de familias de pavimentos de características similares. La normalidad medida mediante análisis de residuos, no permite extrapolar dichos resultados en base a intervalos de confianza. Recomendando su uso a medida que se obtengan más datos de análisis o probando una combinación de familias distintas a las analizadas en este trabajo.
- Que en términos de tiempo requerido para que los modelos puedan ajustarse a los datos analizados, se encontró que el tiempo no es factor determinante para seleccionar un modelo sobre otro. Asimismo el tiempo que requiere cada algoritmo para ajustarse a los datos, varia de acuerdo a la complejidad del algoritmo y el numero de hiperparámetros a ajustar.

### 7.0.3 Recomendaciones Prácticas y futuras líneas de investigación

Adicionalmente, de esta investigación se desprenden las siguientes recomendaciones técnicas y prácticas para poder desarrollar modelos de desempeño de pavimentos aeroportuarios en Chile o en la región, como también a otros tipos de infraestructura:

- Es altamente recomendable, que las instituciones a cargo de la mantención de los pavimentos puedan guardar registros de inventarios e información sobre intervenciones hechas en los pavimentos o auscultación de los mismos. Esto ayuda en la actualización de los modelos de desempeños desarrollados y a su vez mejora la calidad de la predicción con un rango de características más amplio que incrementa la confiabilidad de los modelos.
- Se debe contar con protocolos de auscultación de pavimentos que indiquen los procedimientos a realizar, la frecuencia de inspección, la ubicación (georeferenciada) y quién será el encargado de actualizar la información en la base de datos. La actualización es importante, dado que la investigación arrojó que dada la rotación de personal hay información que se pierde.
- Este trabajo, es un buen punto de partida para seleccionar algunas características a medir para elaborar modelos de desempeño de pavimento basado en PCI, por lo que se recomienda su recolección de manera periódica.

Finalmente, algunos tópicos no cubiertos por este trabajo y que pueden servir de punto de partida para futuras líneas investigaciones, se indican a continuación:

- Aún cuando los resultados obtenidos mostraron una gran capacidad para estimar el índice PCI. Se recomienda actualizar la base de datos y actualizar los modelos, para ampliar el rango de aplicación de ellos. Ya que en este caso, solo pavimentos de asfalto fueron usados para estimar el valor de PCI. Además, se recomienda explorar otro tipo de variables asociadas a los deterioros para estimarlo, en especial asociadas a la variable tránsito aéreo y a los deterioros medidos en encuestas para calcular PCI.
- Adicionalmente, se puede explorar el uso de ML en la proyección de demanda aéreas donde existe una base de datos considerable recogida por la DGAC; y considerando además que los consultores que hacen esta tarea solo han reportado el uso de series de tiempo.

# Referencias

- Abaza, K. A. (2016). Back-calculation of transition probabilities for markovian-based pavement performance prediction models. *International Journal of Pavement Engineering*, 17(3):253–264.
- Abdelaziz, N., Abd El-Hakim, R. T., El-Badawy, S. M., and Afify, H. A. (2020). International roughness index prediction model for flexible pavements. *International Journal of Pavement Engineering*, 21(1):88–99.
- Abdelrahim, A. M. and George, K. (2000). Artificial neural network for enhancing selection of pavement maintenance strategy. *Transportation research record*, 1699(1):16–22.
- Abou Chacra, D. and Zelek, J. (2018). Municipal infrastructure anomaly and defect detection. In *2018 26th European Signal Processing Conference (EUSIPCO)*, pages 2125–2129. IEEE.
- AC150/5380-7B, C. (2014). 150/5380-7b. *Guidelines and Procedures for Maintenance of Airport*.
- Al-Suleiman, T., Shiyab, A., and Al-Masaeid, H. (1996). Development of models for prediction of airfield pavement deterioration. *Road and Transport Research*, 5(3).
- Alharbi, F. (2018). Predicting pavement performance utilizing artificial neural network (ann) models.
- Alimoradi, S., Golroo, A., and Asgharzadeh, S. M. (2020). Development of pavement roughness master curves using markov chain. *International Journal of Pavement Engineering*, pages 1–11.
- Alvarez, J. (2020). Desarrollo de una base de datos para la implementación de un sistema de gestión de pavimentos aeroportuarios para la red aeroportuaria nacional.
- Amat, j. (2021). Ciencia de datos, estadística, machine learning y programación.
- Arambula, E., George, R., Xiong, W., and Hall, G. (2011). Development and validation of pavement performance models for the state of maryland. *Transportation research record*, 2225(1):25–31.

- Ashtiani, A., Shirazi, H., Murrell, S., Brill, D., and Speir, R. (2019). Performance model development for extended airport pavement life. In *Airfield and Highway Pavements 2019: Innovation and Sustainability in Highway and Airfield Pavement Technology*, pages 240–250. American Society of Civil Engineers Reston, VA.
- Augustaukas, R. and Lipnickas, A. (2019). Pixel-wise road pavement defects detection using u-net deep neural network. In *2019 10th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)*, volume 1, pages 468–471. IEEE.
- Bagnato, J. I. (2017). Qué es overfitting y underfitting y cómo solucionarlo.
- Barua, L. and Zou, B. (2021). Planning maintenance and rehabilitation activities for airport pavements: A combined supervised machine learning and reinforcement learning approach. *International Journal of Transportation Science and Technology*.
- Barua, L., Zou, B., Noruzoliaee, M., and Derrible, S. (2020). A gradient boosting approach to understanding airport runway and taxiway pavement deterioration. *International Journal of Pavement Engineering*, pages 1–15.
- Bashar, M. Z. and Torres-Machi, C. (2021). Performance of machine learning algorithms in predicting the pavement international roughness index. *Transportation Research Record*, page 0361198120986171.
- Bayrak, M. B. and Ceylan, H. (2008). Neural network-based approach for analysis of rigid pavement systems using deflection data. *Transportation Research Record*, 2068(1):61–70.
- Behrens, J. T. (1997). Principles and procedures of exploratory data analysis. *Psychological Methods*, 2(2):131.
- Bhavsar, H. and Ganatra, A. (2012). A comparative study of training algorithms for supervised machine learning. *International Journal of Soft Computing and Engineering (IJSCE)*, 2(4):2231–2307.
- Bontempi, G., Taieb, S. B., and Le Borgne, Y.-A. (2012). Machine learning strategies for time series forecasting. In *European business intelligence summer school*, pages 62–77. Springer.
- Brownlee, J. (2016). *Machine learning mastery with Python: understand your data, create accurate models, and work projects end-to-end*. Machine Learning Mastery.
- Brownlee, j. (2021). Machine Learning Mastery.

- Butt, A. A., Shahin, M., Carpenter, S. H., and Carnahan, J. V. (1994). Application of markov process to pavement management systems at network level. In *3rd International conference on managing pavements*, volume 2, pages 159–172. Citeseer.
- Caltrans, C. D. o. T. (2008). Maintenance technical advisory guide, 2nd ed., office of pavement preservation, division of maintenance, sacramento.
- Camahan, J., Davis, W., Shahin, M., Keane, P., and Wu, M. (1987). Optimal maintenance decisions for pavement management. *Journal of Transportation Engineering*, 113(5):554–572.
- Camarena, K. A., Eng, B., and Flores, L. (2018). Proposal of numerical model for airport pavement management purposes.
- Ceylan, H., Bayrak, M. B., and Gopalakrishnan, K. (2014). Neural networks applications in pavement engineering: A recent survey. *International Journal of Pavement Research & Technology*, 7(6).
- Chamorro, A., Tighe, S. L., Li, N., and Kazmierowski, T. J. (2009). Development of distress guidelines and condition rating to improve network management in ontario, canada. *Transportation Research Record*, 2093(1):128–135.
- Chen, D. and Mastin, N. (2016). Sigmoidal models for predicting pavement performance conditions. *Journal of Performance of Constructed Facilities*, 30(4):04015078.
- Chen, W. and Zheng, M. (2021). Multi-objective optimization for pavement maintenance and rehabilitation decision-making: A critical review and future directions. *Automation in Construction*, 130:103840.
- Chicco, D. (2017). Ten quick tips for machine learning in computational biology. *BioData mining*, 10(1):1–17.
- Choi, J.-H., Adams, T. M., and Bahia, H. U. (2004). Pavement roughness modeling using back-propagation neural networks. *Computer-Aided Civil and Infrastructure Engineering*, 19(4):295–303.
- Chollet, F. (2017). *Deep learning with Python*. Simon and Schuster.
- Cohen, H. (2018). *Return on Investment in Transportation Asset Management Systems and Practices*. Number Project 20-100. The National Academies Press.
- Covalt, M., Raczowski, L., and Fisher, M. (2019). A review of state airport pavement management practices and airport pavement conditions in the united states from 2003 through 2016. *Pavement and Asset Management*, pages 29–34.

- DAP (2021). *Ámbito de acción*.
- DataFlair (2021). *Advantages and Disadvantages of Machine Learning Language*.
- Delgadillo, R., Segovia, M., Wahr, C., and Thenoux, G. (2017). Zonificación superpave para chile. *Revista ingeniería de construcción*, 32(1):25–36.
- Di Mascio, P. and Moretti, L. (2019). Implementation of a pavement management system for maintenance and rehabilitation of airport surfaces. *Case Studies in Construction Materials*, 11:e00251.
- Domitrović, J., Dragovan, H., Rukavina, T., and Dimter, S. (2018). Application of an artificial neural network in pavement management system. *Tehnički vjesnik*, 25(Supplement 2):466–473.
- Díaz, C. (2021). Desarrollo de herramientas de visualización de aplicaciones de machine learning en modelos de comportamiento de pavimentos.
- El-Diraby, T. E., Kinawy, S., and Piryonosi, S. M. (2017). A comprehensive review of approaches used by ontario municipalities to develop road asset management plans. *Transportation Research Board 96th Annual Meeting Transportation Research Board*, (17-00281).
- El-Hakim, A., El-Badawy, S., et al. (2013). International roughness index prediction for rigid pavements: an artificial neural network application. In *Advanced Materials Research*, volume 723, pages 854–860. Trans Tech Publ.
- Falls, L. C., Khalil, S., Hudson, W. R., and Haas, R. (1994). Long-term cost-benefit analysis of pavement management system implementation. *Transportation Research Board*, 2:133–138.
- Fathi, A., Mazari, M., Saghafi, M., Hosseini, A., and Kumar, S. (2019). Parametric study of pavement deterioration using machine learning algorithms. In *Airfield and highway pavements 2019: Innovation and sustainability in highway and airfield pavement technology*, pages 31–41. American Society of Civil Engineers Reston, VA.
- Gao, S., Jie, Z., Pan, Z., Qin, F., and Li, R. (2018). Automatic recognition of pavement crack via convolutional neural network. In *Transactions on Edutainment XIV*, pages 82–89. Springer.
- Gendreau, M. and Soriano, P. (1998). Airport pavement management systems: An appraisal of existing methodologies. *Transportation Research Part A: Policy and Practice*, 32(3):197–214.
- Georgiou, P., Plati, C., and Loizos, A. (2018). Soft computing models to predict pavement roughness: A comparative study. *Advances in Civil Engineering*, 2018.

- Gerardi, M. (2015). The boeing bump index—additional methodologies recommended. *APR consultants*.
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media.
- Gong, H., Sun, Y., and Huang, B. (2019). Estimating asphalt concrete modulus of existing flexible pavements for mechanistic-empirical rehabilitation analyses. *Journal of Materials in Civil Engineering*, 31(11):04019252.
- Gong, H., Sun, Y., Shu, X., and Huang, B. (2018). Use of random forests regression for predicting IRI of asphalt pavements. *Construction and Building Materials*, 189:890–897.
- Gopalakrishnan, K. and Papadopoulos, H. (2011). Reliable pavement backcalculation with confidence estimation. *Scientia Iranica*, 18(6):1214–1221.
- Guignier, F. and Madanat, S. (1999). Optimization of infrastructure systems maintenance and improvement policies. *Journal of infrastructure systems*, 5(4):124–134.
- Haas, R. and Hudson, W. R. (2015). *Pavement asset management*. John Wiley & Sons.
- Haas, R., Hudson, W. R., and Zaniewski, J. P. (1994). *Modern pavement management*.
- Hafez, M., Ksaibati, K., and Atadero, R. A. (2019). Optimizing expert-based decision-making of pavement maintenance using artificial neural networks with pattern-recognition algorithms. *Transportation Research Record*, 2673(11):90–100.
- Hajek, J. J. (2011). *Common airport pavement maintenance practices*, volume 22. Transportation Research Board.
- Hassan, R., Lin, O., and Thananjeyan, A. (2017). A comparison between three approaches for modelling deterioration of five pavement surfaces. *International Journal of Pavement Engineering*, 18(1):26–35.
- Hicks, R. G., Moulthrop, J. S., and Daleiden, J. (1999). Selecting a preventive maintenance treatment for flexible pavements. *Transportation research record*, 1680(1):1–12.
- Hoang, N.-D. and Nguyen, Q.-L. (2019). A novel method for asphalt pavement crack classification based on image processing and machine learning. *Engineering with Computers*, 35(2):487–498.
- Hossain, M., Gopiseti, L. S. P., and Miah, M. S. (2020). Artificial neural network modelling to predict international roughness index of rigid pavements. *International Journal of Pavement Research and Technology*, pages 1–11.

- Huang, S.-M., Hsu, C.-J., Lee, C., and Chang, C.-C. (2005). Application of neural network for selection of airport rigid pavement maintenance strategies. *Journal of Marine Science and Technology*, 13(2):125–132.
- Huincalef, R., Urrutia, G., Ingravallo, G., and Martínez, D. C. (2018). An approach to automated recognition of pavement deterioration through machine learning. In *Argentine Congress of Computer Science*, pages 124–140. Springer.
- Inkoom, S., Sobanjo, J., Barbu, A., and Niu, X. (2019). Prediction of the crack condition of highway pavements using machine learning models. *Structure and Infrastructure Engineering*, 15(7):940–953.
- Irfan, M., Khurshid, M. B., Iqbal, S., and Khan, A. (2015). Framework for airfield pavements management—an approach based on cost-effectiveness analysis. *European Transport Research Review*, 7(2):13.
- Jalal, M., Floris, I., and Quadrioglio, L. (2017). Computer-aided prediction of pavement condition index (pci) using ann. In *Proceedings of the international conference on computers and industrial engineering, CIE*.
- Justo-Silva, R., Ferreira, A., and Flintsch, G. (2021). Review on machine learning techniques for developing pavement performance prediction models. *Sustainability*, 13(9):5248.
- Karamihas, S. M. and Sayers, M. W. (1998). The little book of profiling. *Transportation Research Institute, University of Michigan: Ann Arbor, MI, USA*.
- Karbalaeezadeh, N., Zaremotekhas, F., Shamshirband, S., Mosavi, A., Nabipour, N., Csiba, P., and 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.
- Kargah-Ostadi, N. (2014). Comparison of machine learning techniques for developing performance prediction models. In *Computing in Civil and Building Engineering (2014)*, pages 1222–1229.
- Khazanovich, L. and Roesler, J. (1997). Diploback: Neural-network-based backcalculation program for composite pavements. *Transportation Research Record*, 1570(1):143–150.
- Kim, S.-H. and Kim, N. (2006). Development of performance prediction models in flexible pavement using regression analysis method. *KSCE Journal of Civil Engineering*, 10(2):91–96.
- Kırbaş, U. and Kardeş, M. (2016). Performance models for hot mix asphalt pavements in urban roads. *Construction and Building Materials*, 116:281–288.

- Kohler, E. (2014). Medición de irregularidad superficial en pavimentos de aeropuertos, viales y ciclovías. *Estudios de Transporte*, 18(2).
- Kwak, P.-J., Kim, D.-H., Kim, S.-J., and Jeong, J.-H. (2020). Development of a non-linear pci model for homogeneous zones of concrete airport pavements. In *Proceedings of the Institution of Civil Engineers-Transport*, pages 1–15. Thomas Telford Ltd.
- Leiva-Villacorta, F., Vargas-Nordbeck, A., and Timm, D. H. (2017). Non-destructive evaluation of sustainable pavement technologies using artificial neural networks. *International Journal of Pavement Research and Technology*, 10(2):139–147.
- Lin, J.-D., Yau, J.-T., and Hsiao, L.-H. (2003). Correlation analysis between international roughness index (iri) and pavement distress by neural network. In *82nd Annual Meeting of the Transportation Research Board*, pages 12–16.
- Luengo, J., García, S., and Herrera, F. (2009). A study on the use of statistical tests for experimentation with neural networks: Analysis of parametric test conditions and non-parametric tests. *Expert Systems with Applications*, 36(4):7798–7808.
- Luo, Z. (2013). Pavement performance modelling with an auto-regression approach. *International Journal of Pavement Engineering*, 14(1):85–94.
- Machí, C. T. (2015). *Optimización heurística multiobjetivo para la gestión de activos de infraestructuras de transporte terrestre*. Pontificia Universidad Católica de Chile (Chile).
- Magaña-Cubillo, J., Hernández-Vega, H., and Jiménez-Romero, D. (2014). Aplicación del análisis de conglomerados para la caracterización de factores temporales de tránsito.
- Marcelino, P., de Lurdes Antunes, M., Fortunato, E., and Gomes, M. C. (2021). Machine learning approach for pavement performance prediction. *International Journal of Pavement Engineering*, 22(3):341–354.
- Marcobal, J. R., Diaz, R., Márquez, W., and Saldaña, D. (2017). Evaluación de la rugosidad (iri) en caminos pavimentados de geometría restringida: Cálculo del iri geométrico-caso de aplicación. In *Congreso Ibero-Latinoamericano del Asfalto. Medellín Colombia*.
- May, R., Dandy, G., and Maier, H. (2011). Review of input variable selection methods for artificial neural networks. *Artificial neural networks-methodological advances and biomedical applications*, 10:16004.

- Mazari, M. and 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.
- MDOT, M. D. o. T. (2010). Capital preventive maintenance, 2003 ed., construction and technology division, lansing.
- Mills, L. N. O., Attoh-Okine, N. O., and McNeil, S. (2012). Developing pavement performance models for delaware. *Transportation research record*, 2304(1):97–103.
- Mitchell, J. (2007). Development and implementation of an airfield pavement management system for the winnipeg international airport.
- Mizusawa, D. and McNeil, S. (2005). Quantify the benefits of implementing asset management. In *1st Annual Inter-university Symposium on Infrastructure Management (AISIM)*.
- Mizusawa, D. and McNeil, S. (2009). Generic methodology for evaluating net benefit of asset management system implementation. *Journal of infrastructure systems*, 15(3):232–240.
- MnDOT, M. D. o. T. (2009). Preventive maintenance best management practices of hot mix asphalt pavements, report mn/rc-2009-18, office of materials and road research, maplewood.
- Montoya, D. M., López, M. R., and Acosta, P. M. (2016). Análisis del índice de rugosidad internacional. aplicación al aeropuerto enrique olaya herrera de medellín, colombia. *UGCiencia*, 22(1):57–69.
- MOP (2011). Decreto 317: Adjudica contrato de concesión para la ejecución, reparación, conservación y explotación de la obra pública fiscal denominada "aeropuerto cerro moreno de antofagasta". *Diario Oficial*.
- Moreno, M. R., Zeballos, G. T., and Vaccarezza, A. G. (2013). Probabilistic assessment of cracking in asphalt pavements in chilean roads. *Revista de la Construccion*, pages 152–165.
- NIT–SCT (2006). *normativa para la infraestructura del transporte: manuales 2006*. NIT SCT.
- Noruzoliaee, M. and Zou, B. (2019). Airfield infrastructure management using network-level optimization and stochastic duration modeling. *Infrastructures*, 4(1):2.
- ODOT, O. D. o. T. (2001). Pavement preventive maintenance guidelines, office of pavement engineering, columbus.

- Ortiz-García, J. J., Costello, S. B., and Snaith, M. S. (2006). Derivation of transition probability matrices for pavement deterioration modeling. *Journal of Transportation Engineering*, 132(2):141–161.
- Osorio, L., Delgadillo, R., and Whar, C. (2015). Caracterización y análisis de la estadística chilena para el diseño de pavimentos empírico-mecanicista. *Revista Ingeniería de Obras Civiles*, 5:20–25.
- Osorio-Lird, A., Chamorro, A., Videla, C., Tighe, S., and 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.
- Papagiannakis, A., Bracher, M., and Jackson, N. (2006). Utilizing clustering techniques in estimating traffic data input for pavement design. *Journal of Transportation Engineering*, 132(11):872–879.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- Piryonesi, S. and El-Diraby, T. (2017). A data analytics solution for predicting the pavement condition index of roads using the most affordable attributes. *CSCE: Leadership in Sustainable Infrastructure. Canadian Society for Civil Engineering, Vancouver*, pages 1–9.
- Piryonesi, S. and El-Diraby, T. (2019). A machine-learning solution for quantifying the impact of climate change on roads. In *CSCE Annual Conference. Canadian Society for Civil Engineering, Laval*.
- Pulugurta, H., Shao, Q., and Chou, Y. (2009). Pavement condition prediction using markov process. *Journal of Statistics and Management Systems*, 12(5):853–871.
- Qian, Z., Huang, W., Tan, M., and Yang, L. (2000). Pavement management system for nanjing airport freeway. In *Traffic and Transportation Studies (2000)*, pages 265–270.
- Qiao, Y., Flintsch, G. W., Dawson, A. R., and Parry, T. (2013). Examining effects of climatic factors on flexible pavement performance and service life. *Transportation research record*, 2349(1):100–107.
- Rebala, G., Ravi, A., and Churiwala, S. (2019). Machine learning definition and basics. In *An Introduction to Machine Learning*, pages 1–17. Springer.

- Rioseco and Tesser (2006). Cartografía Interactiva de los climas de Chile [en línea].
- Roberts, C. A. and 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.
- Rojas, V. (2017). Proposición de modelo matemático para la priorización de recursos, destinados a labores de conservaciones de pavimentos aeroportuarios.
- Rosenblatt, F. (1957). *The perceptron, a perceiving and recognizing automaton Project Para*. Cornell Aeronautical Laboratory.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3):210–229.
- Sánchez, I. and de Solminihac, H. (2012). El iri: un indicador de la regularidad superficial. *Revista Ingeniería de Construcción*, (6):1–17.
- Sayers, M. W. (1986). The international road roughness experiment: establishing correlation and a calibration standard for measurements. Technical report, University of Michigan, Ann Arbor, Transportation Research Institute.
- Shahin, M. Y. (1994). *Pavement management for airports, roads, and parking lots*.
- Shahnazari, H., Tutunchian, M. A., Mashayekhi, M., and Amini, A. A. (2012). Application of soft computing for prediction of pavement condition index. *Journal of Transportation Engineering*, 138(12):1495–1506.
- Shatnawi, S., Antonucci, C., and Hicks, R. G. (2005). Development of the caltrans maintenance technical advisory guide. *Roadway Pavement Preservation*, page 132.
- Smadi, O. (2004). Quantifying the benefits of pavement management. In *6th International Conference on Managing Pavements: The Lessons, The Challenges, The Way Ahead* Queensland Department of Main RoadsARRBFRH GroupExor CorporationPavement Management ServicesFederal Highway AdministrationWorld HighwaysGHDBrisbane City CouncilTasmania Department of Infrastructure, Energy and ResourcesAustralian Road Federation (ARF) HansenCooperative Research Centre for Construction Innovation.
- Solminihac, T., Echaveguren, T., and Chamorro, A. (2018). Gestión de infraestructura vial.
- Solorio Murillo, J., MARQUEZ MENDOZA, Z., MONTOYA ORTEGA, M., CARDENAS RODRIGUEZ, S., and HERNANDEZ DOMINGUEZ, R. (2014). Aplicacion de metodos markovianos en el modelado del deterioro de carreteras. *Publicacion Tecnica*, (396).

- Suh, Y.-C., Park, D.-Y., and Jeong, K.-Y. (2002). Development of deterioration prediction models for airfield rigid pavements. *Transportation research record*, 1788(1):132–137.
- Sukhobok, Y., Verkhovtsev, L., and Ponomarchuk, Y. (2019). Automatic evaluation of pavement thickness in gpr data with artificial neural networks. In *IOP Conference Series: Earth and Environmental Science*, volume 272, page 022202. IOP Publishing.
- Sztraka, J. K. and Eng, P. (2001). Quantifiable benefits of pavement management in aid of setting and achieving goals. In *Proc., 5th Int. Conf. on Managing Pavements (CD-ROM), Seattle, Wash., Paper*, volume 24. Citeseer.
- Tabatabaee, N., Ziyadi, M., and 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.
- The World Bank (2020). Air transport.
- 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.
- Tighe, S. E. (2013). Pavement asset design and management guide.
- Tighe, S. L. and Covalt, M. (2008). Implementation of an airport pavement management system. *Transportation Research Circular*, (E-C127).
- Tolmo, M. (2020). Formulaci3n de un marco te3rico para la gesti3n de pavimentos aeroportuarios, aplicable a la red nacional de aeropuertos.
- Torres-Machi, C., Osorio-Lird, A., Chamorro, A., Videla, C., Tighe, S. L., and Mourgues, C. (2018). Impact of environmental assessment and budgetary restrictions in pavement maintenance decisions: Application to an urban network. *Transportation Research Part D: Transport and Environment*, 59:192–204.
- Trawinski, B., Smketek, M., Telec, Z., and Lasota, T. (2012). Nonparametric statistical analysis for multiple comparison of machine learning regression algorithms. *International Journal of Applied Mathematics and Computer Science*, 22:867–881.
- Vera, I., Thenoux, G., Solminihac, H., and Echaveguren, T. (2010). Modelo de evaluaci3n t3cnica del desempe1o del mantenimiento de pavimentos flexibles. *Revista de la Construcci3n*, 9(2):76–88.

- Wang, Z., Guo, N., Wang, S., and Xu, Y. (2021). Prediction of highway asphalt pavement performance based on markov chain and artificial neural network approach. *Journal of Supercomputing*, 77(2).
- White, G. (2017). Managing skid resistance and friction on asphalt runway surfaces. In *Proceedings of the World Conference on Pavement and Asset Management, Milan, Italy*, pages 12–16.
- Yan, K. Z. and Zhang, Z. (2011). Research in analysis of asphalt pavement performance evaluation based on pso-svm. In *Applied Mechanics and Materials*, volume 97, pages 203–207. Trans Tech Publ.
- Yang, J. (2004). Road crack condition performance modeling using recurrent markov chains and artificial neural networks.
- Yang, J., Lu, J. J., Gunaratne, M., and Dietrich, B. (2006). Modeling crack deterioration of flexible pavements: Comparison of recurrent markov chains and artificial neural networks. *Transportation research record*, 1974(1):18–25.
- Yao, L., Dong, Q., Jiang, J., and Ni, F. (2019). Establishment of prediction models of asphalt pavement performance based on a novel data calibration method and neural network. *Transportation Research Record*, 2673(1):66–82.
- Younos, M., Abd El-Hakim, R., El-Badawy, S., and Afify, H. (2020). Multi-input performance prediction models for flexible pavements using ltp database. *Innovative Infrastructure Solutions*, 5(1):1–11.
- Yuan, J. and Mooney, M. A. (2003). Development of adaptive performance models for oklahoma airfield pavement management system. *Transportation research record*, 1853(1):44–54.
- Zhang, A., Wang, K. C., Li, B., Yang, E., Dai, X., Peng, Y., Fei, Y., Liu, Y., Li, J. Q., and Chen, C. (2017a). Automated pixel-level pavement crack detection on 3d asphalt surfaces using a deep-learning network. *Computer-Aided Civil and Infrastructure Engineering*, 32(10):805–819.
- Zhang, H., Keoleian, G. A., Lepech, M. D., and Kendall, A. (2010). Life-cycle optimization of pavement overlay systems. *Journal of infrastructure systems*, 16(4):310–322.
- Zhang, L., Fu, L., Gu, W., Ouyang, Y., and Hu, Y. (2017b). A general iterative approach for the system-level joint optimization of pavement maintenance, rehabilitation, and reconstruction planning. *Transportation Research Part B: Methodological*, 105:378–400.

Ziari, H., Maghrebi, M., Ayoubinejad, J., and Waller, S. T. (2016). Prediction of pavement performance: application of support vector regression with different kernels. *Transportation Research Record*, 2589(1):135–145.

Zimmerman, K. A. and Bahulkar, A. M. (1998). Statistical methods for pavement performance curve building, historical analysis, data sampling and storage. Technical report.

# Appendix A

## Método PCI

El primer paso para la evaluación de los pavimentos mediante la norma ASTM D-5340 "Standard Test Method for Airport Pavement Condition Index Surveys", es la identificación de redes, ramas y unidades muestrales. ramas; siendo las ramas — y las ramas — . La secciones características, corresponde aquellos pavimentos similares que comparten un mismo diseño, tráfico, condición u otro criterio definido por los consultores. Por último, las unidades muestrales es la unidad física donde se realiza la inspección y registro de deterioros.

El procedimiento de determinación de PCI en cada unidad de muestral se describe a continuación.

- **Paso 1: Cálculo de los valores deducidos:**

- Totalizar por cada tipo de deterioro y severidad la cantidad total del daño medido en área, longitud o número según su tipo.
- Dividir la cantidad total de daño según el tipo de deterioro, entre el área total de la unidad de muestreo (losas en el caso de pavimentos de hormigón PCC) expresando el resultado en porcentajes.
- Determinar el valor deducido para cada tipo de deterioro y nivel de severidad mediante las curvas denominadas "Valor deducido del daño para pavimentos de Asfalto" que se adjuntan en la sección de cálculos de PCI.

- **Paso 2: Cálculo del número máximo admisible de valores deducidos**

- Si ninguno o tan sólo uno de los valores deducidos es mayor que 2, se usa el valor deducido total en lugar del mayor "valor deducido corregido", CDV en el paso 4. En

caso contrario, se deben ordenar de mayor a menor los valores deducidos individuales y determinar el número máximo admisible de valores deducidos  $m$ , calculado como sigue:

$$m_i = 1 + \frac{9 \cdot (100 - HDV_i)}{9.8} < 10 \quad (\text{A.1})$$

Donde:  $HDV_i$ =máximo valor deducido ;  $m_i$ =número máximo admisible de valores deducido  $m$ .

- El número de valores individuales deducidos se reduce a  $m$ , inclusive la parte fraccionaria. Si se dispone de menos valores deducidos de  $m$  se utilizan todos los que se tengan.

- **Paso 3: Cálculo del Máximo Valor deducido Corregido (CDV)**

- Determinar el número de valores deducidos,  $q$ , mayores que 2.
- Determinar el “Valor Deducido Total” sumando todos los valores deducidos individuales.
- Determinar el CDV con  $q$  y el valor Deducido Total en la curva de corrección pertinente al tipo de pavimento de asfalto.
- Reducir a 2 el menor de los Valores Deducidos individuales que sea mayor que 2 y repetir los pasos anteriores hasta que  $q$  sea igual a 1.
- El máximo CDV es el mayor de los CDV obtenidos en este proceso.

- **Paso 4: Calcular el PCI de la unidad restando de 100 el máximo CDV**

# Appendix B

## Descripción Base de Datos

Tabla B.1: Estructura Base de datos propuesta Alvarez (2020).

Inventario de la Red	Componentes de la Red	Ubicaciones (Aeropuertos)	Listado de todos los aeródromos existentes en el territorio nacional. Representa el inicio de la cadena jerárquica y están representados por el código único que le asigna la Organización de Aviación Civil Internacional. Código OACI
		Activos	Representa uno de los dos tipos de infraestructura presentes en aeropuertos. Pueden ser: Horizontales: Representa la infraestructura que se encuentra en el Área de Movimiento Verticales: En representación de la infraestructura restante asociada al Lado Tierra.
		Sub-Activos (Ramas)	Ramas de los pavimentos existentes en los Activos Horizontales, puede ser: Pista - Rodaje - Plataforma
		Secciones Características	Define las secciones en las que se dividen las ramas en cada uno de los aeropuertos, representadas por un código único por cada aeropuerto.
		Unidades de Muestra	Unidades Muestrales presentes en cada una de las secciones definidas, representadas por números.
	Información General	Nombre	Corresponde al Nombre Propio designado para cada uno de los aeropuertos de la red aeroportuaria nacional.
		Tipo	Tipo de Aeródromo, haciendo referencia a si califica o no como un Aeropuerto, puede ser: Aeropuerto - Aeródromo
		Propiedad	Especifica la propiedad del aeródromo, usualmente puede ser: Municipal - Privado - Fiscal
		Macrozona	Referencia a una de las cuatro macrozonas geográficas en las que se divide el territorio chileno, pueden ser: Norte (MN) - Centro (MC) - Sur (MS) - Austral (MA)
		Red	Asocia cada aeropuerto a cada una de las cuatro redes existentes: Primaria - Secundaria - Red de Pequeños Aeródromos - Red de Aeródromos Militares
		Concesión	Afirma si un aeródromo es o no concesionado: SI: Aeródromo concesionado - NO: Aeródromo no concesionado
		Nro Teléfono	Número de teléfono de la oficina de administración del aeródromo
	Especificaciones	Código de Referencia Aeroportuario	Código de referencia aeroportuario de la Organización de Aviación Civil Internacional que consta de un número y una letra. El código combinado de número y letra clave de referencia indica qué aeronaves pueden operar en el aeródromo (APENDICE)
		Código IATA	Código asignado por la Asociación Internacional de Transporte Aéreo (IATA, por sus siglas en inglés), está formado por grupos de tres letras, que designan a cada aeropuerto del mundo. A diferencia del código identificador OACI, el código IATA se usa principalmente para aeropuertos con operaciones nacionales e internacionales de transporte de pasajeros, no para todos los existentes en el mundo
		Administración	Entidad que administra el Aeropuerto, puede ser la misma DGAC, Municipalidades, instituciones (FACH, Carabineros u otras instituciones), privados u otros según
		Uso	Especifica quien puede hacer uso de los aeródromos, puede ser: Público (PUB) - Militar (MIL) - Privado (PVT)
		Aproximación	Determina si un aeropuerto tiene capacidad para realizar aterrizaje instrumental bajo las reglas de vuelo instrumental (IFR, por sus siglas en inglés), o solo reglas de vuelo visual sin instrumentos (VFR, por sus siglas en inglés)
		VOR	Informa si el aeródromo cuenta con una estación terrestre de Radiofaro Omnidireccional de Muy Alta Frecuencia (VOR, por sus siglas en inglés), el cual es una radioayuda a la navegación que utilizan las aeronaves para seguir en vuelo una ruta preestablecida.
		Tipo VOR	Además del sistema VOR tradicional, las estaciones suelen venir acompañadas de otra radioayuda llamada DME (Distance Measurement Equipment), que ayuda al piloto a conocer la distancia que hay entre la aeronave y la estación VOR-DME. Aquí se especifica si la estación es de tipo VOR o VOR/DME.
		ILS	Informa si el aeródromo cuenta con un sistema de aterrizaje instrumental (ILS, por sus siglas en inglés), que es el sistema de ayuda a la aproximación y el aterrizaje establecido por la OACI como sistema normalizado en todo el mundo.
Categoría ILS		El sistema ILS se divide en categorías según qué tan avanzado sea, las categorías están detalladas en el APENDICE	
Horas Op.		Explicita las horas de funcionamiento del aeródromo, usualmente dadas por: H24: Durante las 24 horas del día HJ: Desde comienzo crepúsculo civil matutino hasta el fin crepúsculo civil vespertinoDEF	

Inventario de la Red	Especificaciones	Facilidades para los usuarios	Especifica el tipo de facilidades para los pasajeros, en general: <b>TERMINAL (Terminal de pasajeros) - MILITAR (Instalaciones militares) - OTROS</b>
		Superficie Terminal de	En caso de que el aeródromo cuente con terminal de pasajeros se especifica el área de la superficie en metros cuadrados
		Estacionamientos para aeronaves	En caso de que el aeródromo cuente con estacionamientos para aeronaves comerciales se especifica la cantidad existente.
		Puentes de Embarque para	En caso de que el aeródromo cuente con puentes para embarque (pasarelas de acceso a la aeronave) se especifica la cantidad existente.
		Posiciones remotas para	Posición de estacionamiento de aeronave con una ubicación alejada del edificio terminal. Si el aeródromo cuenta con ellas, se especifica la cantidad existente.
		Estacionamientos vehiculares	En caso de que el aeródromo cuente con estacionamientos vehiculares, se especifica la cantidad existente.
		Aviación opera mayoritariamente	Si bien los aeropuertos suelen recibir distintos tipos de operaciones, la mayoría tiene operaciones mayoritarias marcadas, pueden ser: <b>COMERCIAL (Transporte de pasajeros y cargo) - MILITAR (Operación de aeronaves militares) - GENERAL (Usualmente aeronaves privadas)</b>
		Categoría SSEI del Aeródromo	Categoría de protección del aeródromo a efectos del servicio de salvamento y extinción de incendios y rescate de aeronaves conforme a lo establecido por la DGAC. Detalles de las categorías y lo que representan en el <b>APENDICE(DAN14)</b>
		SSEI Horas Op.	Horas en que operan los servicios de SSEI, por lo general: H24: Durante las 24 horas del día HJ: Desde comienzo crepúsculo civil matutino hasta el fin crepúsculo civil vespertino
		SSEI Equipo	Informa si se cuenta o no con el equipo de salvamento mínimo requerido según la categoría SSEI del aeródromo
	AIP CHILE Cámaras de aeródromo (IFIS)	Se informa si el aeropuerto cuenta o no con cámaras que registran imágenes de los aeródromos de IFIS (Internet Flight Information Service) requerido por AIP CHILE (Manual básico de información aeronáutica bajo las órdenes de la DGAC)	
	Ubicación	País	País donde se encuentra el aeródromo, para el caso de este documento que trata de la red aeroportuaria de chilena, todos los aeródromos se encuentran en Chile
		Localidad	Referencia usualmente al "sector" donde se ubica un aeropuerto, si bien no está geográficamente definido, una localidad tiende a estar influenciado por la ciudad más cercana, la región a la que pertenece, o el nombre con el que la población aledaña reconoce el sector
		Región	Nombre de la Región a la que pertenece el aeródromo. Restringido a las 16 regiones reconocidas como las divisiones territoriales superiores de Chile. ( <b>APENDICE</b>
		Provincia	Nombre de la Provincia a la que pertenece el aeródromo. Restringido a las provincias que se encuentran en la región donde se ubica el aeródromo, las provincias son las subdivisiones territoriales de las regiones para conceptos administrativos.
		Comuna	Nombre de la Comuna a la que pertenece el aeródromo. Las comunas son la división administrativa menor y básica de Chile
		Referencia	Referencia en grados y coordenadas cartesianas aproximadas a un punto de relevante, usualmente la ciudad grande más cercana al aeródromo
		Dirección	Dirección oficial del aeródromo
		Latitud	La latitud exacta del punto de ubicación en coordenadas cartesianas del aeródromo según la Organización de Aviación Civil Internacional
Longitud		La longitud exacta del punto de ubicación en coordenadas cartesianas del aeródromo según la Organización de Aviación Civil Internacional	
Elevación		Elevación del aeródromo respecto al nivel del mar del punto de ubicación del aeródromo según la Organización de Aviación Civil Internacional	
Propiedades de Secciones Características	Tipo Pavimento	Material del cual está compuesta la superficie de la sección, usualmente: <b>Homigón (Para pavimentos rígidos) o Asfalto (Para pavimentos flexibles)</b>	
	Año Construcción	Año en que fue construida la Sección	
	Área	Registra el área de cada una de las Secciones Características en metros cuadrados	
	Cantidad de Unidades de	Informa sobre la cantidad de Unidades de Muestra que componen la sección indicada	

Inventario de la Red	Pista	Cantidad de Pares de Pista	Indica la cantidad de pistas con las que cuenta el aeródromo. Refeido normalmente como "pares" de pistas debido a que cada pista provee de dos direcciones de operación
		Designación	Número de designación de pista representado por la combinación de los números de orientación de los umbrales
		Longitud (m)	Largo total de la pista en metros. El largo total se mide desde el inicio de un umbral hasta el final del umbral opuesto
		Ancho (m)	Ancho de la pista (Excluyendo los márgenes) medida en metros
		Superficie (m2)	Área total disponible para operaciones. Producto del Ancho y Longitud de la pista
		Pend. Long. (%)	Pendiente de la pista en la dirección establecida por el número de designación
		Superficie Pista	Especifica el material del que se compone la superficie de la pista. Normalmente compuesta por Tierra Compactada, Asfalto, Hormigón, Ripio Compactado o Pasto
		Longitud Franja de Seguridad (m)	Longitud de la zona de seguridad de la pista medida en metros
		Ancho Franja de Seguridad (m)	Ancho de la zona de seguridad de la pista medida en metros
		Superficie Franja de Seguridad	Área total de la zona de seguridad asignada a la pista, producto de la longitud y el ancho de la zona de seguridad
Estructura Pavimentos	Información capas del pavimento	Modulo Elástico Subrasante	Valor del módulo elástico representativo de la subrasante medido en megapascals [Mpa]
		Nro Capa	Representa la ubicación de la capa a partir de la subrasante, partiendo usualmente con las capas de base o subbase llegando hasta la capa de rodadura
		Tipo	Especifica a qué tipo de capa de estructura del pavimento corresponde, conformado usualmente por: Subbase - Base - Asfalto - Hormigón
		Año Construcción	Corresponde al año de construcción de la capa representada
		Espesor	Espesor de la capa en centímetros
		Modulo Elástico	Corresponde al Modulo Elástico representativo de la capa, en Megapascals [Mpa]
		Resistencia a la Flexotracción	Para las capas de hormigón se suele entregar mediciones de resistencia a la flexotracción debido a que son mas representativas para este tipo de pavimento, medida en psi
	Capacidad Estructural PCN	Año Medición	Año en el cual se realizó la medición PCN que se está registrando
		Tipo Pavimento	Representa si el pavimento es de tipo Rígido o Flexible, considerar que no siempre corresponde al tipo de la superficie de rodadura
		E [psi]	Módulo de Elasticidad equivalente de la sección (representativa para todo el bloque de pavimento que compone la estructura de la sección) medido en psi
		Rf [psi]	Resistencia a la flexotracción equivalente de la sección, medido en psi (para Pavimentos Rígidos)
		PCN	Valor numérico del PCN de la sección
		Tipo Pavimento (Rodaje)	Código del tipo de pavimento del método ACN-PCN
		Resistencia Suelo Soporte	Código de la resistencia del suelo de soporte del método ACN-PCN
		Presión max. Admisible Neumáticos	Código de la presión máxima admisible de neumático del método ACN-PCN
		Método Evaluación	Código del método de evaluación del método ACN-PCN
		Clasificación	Clasificación de la sección mediante el método ACN-PCN. Corresponde al valor del PCN seguido de los cuatro códigos que lo caracterizan separados por un "slash" ("/")

Historial M&R	Listado Proyectos Realizados	Nombre	Nombre del proyecto de M&R realizado
		Año Ejecución	Año en que se llevó a cabo el proyecto
		Código S.C. Incluidas	Secciones Características que fueron intervenidas (en las que se realizaron obras) por el proyecto
	Obras Realizadas	Nombre o designación	Nombre del procedimiento realizado
		Unidad de Medida	Unidad de medida de la cantidad de trabajo realizado (metros, metros cuadrados, litros, etc.)
		Cantidad	La cantidad de trabajo realizado según la unidad de medida seleccionada
Precio Unitario (\$)		Precio unitario en pesos del trabajo realizado, según la unidad de medida seleccionada y en pesos del momento en que se realizó la intervención	
Precio Unitario (UF)	Precio unitario del trabajo realizado expresado en UF (usando el cambio al momento de realizada la intervención)		
Condición de los Pavimentos	Listado PCI por Sección Característica	Valor PCI	Valor numérico representativo del PCI de la Sección Característica
		Tipo PCI	Especifica si el valor de PCI representado es medido en terreno o resultado de una proyección, puede ser: Medido - Proyectado
		Año PCI	Representa el año en el que este valor de PCI fue obtenido mediante ya sea medición directa o una proyección
	Listado PCI por Unidad de Muestra	Valor PCI	Valor numérico representativo del PCI de la Unidad de Muestra
		Año PCI	Año al que corresponde el PCI de la Unidad de Muestra
	Datos de deterioros por U.M.	Tipo de deterioro	Especifica el tipo de deterioro medido
		Severidad	Indica la severidad del deterioro, puede ser: Alta - Media - Baja - No Aplica
		Cantidad	La cantidad en que se presenta el deterioro de acuerdo a las unidades de medida correspondientes
		Unidad de Medida	Unidad de medida del deterioro según corresponda
	Coeficiente Rozamiento Pista	Año	Año en que fue realizada la medición
		Dirección Pista (Umbral Inicial -)	Dirección de referencia en la que fue realizada la medición. Indica el umbral donde inicia la medida y el umbral hacia el que se dirige
		Distancia hacia la izquierda desde el eje	Usando la dirección de la medición como referencia, indica la distancia desde el centro de la pista hacia la izquierda en metros
		Distancia	Distancia desde el inicio de la pista en el que se mide el valor. Se mide cada diez metros por lo que la distancia siempre resulta un número múltiplo de diez
		Valor coeficiente	Valor de coeficiente de rozamiento medido en el punto correspondiente
	IRI Pista	Pista	Pista del aeropuerto en la que es realizada la medición
		Año	Año en que fue realizada la medición
		Pasada	Representa en que pasada del vehículo que toma la medición fue tomado el dato que corresponda
		Distancia al eje	Distancia desde el centro de la pista. Un número negativo representa que es hacia la izquierda del centro y un número positivo hacia la derecha. El cero es justo en el centro
Tramo medición (km)		Tramo al cual representa el dato medido, se divide en tramos de 200 metros desde el inicio de la pista	
Valor IRI		Valor de IRI medido en el tramo correspondiente	

Demanda y Ambiente	Información climática mensual	Mes	Mes al que representan las mediciones
		T° Mínima	Temperatura mínima registrada en el mes correspondiente en grados Celsius (°C)
		T° Media	Temperatura media registrada en el mes correspondiente en grados Celsius (°C)
		T° Máxima	Temperatura máxima registrada en el mes correspondiente en grados Celsius (°C)
		PP Totales	Precipitaciones totales registradas en el mes correspondiente medida en milímetros
		Radiación Solar Promedio	Radiación solar promedio registrada en el mes correspondiente medida en [kW h/m <sup>2</sup> día]
		Dirección Dominante del	Dirección en coordenadas cartesianas correspondiente a los vientos de mayor potencia del mes correspondiente
		Velocidad Media del Viento	Valor de la velocidad media del viento para el mes correspondiente, medida en nudos [kts]
		Velocidad probable [0-1]	Corresponde al porcentaje de probabilidad durante el mes a que se registren vientos de una potencia entre [0-1] kts
		Velocidad probable [1-7]	Corresponde al porcentaje de probabilidad durante el mes a que se registren vientos de una potencia entre [1-7] kts
		Velocidad probable [7-22]	Corresponde al porcentaje de probabilidad durante el mes a que se registren vientos de una potencia entre [7-22] kts
		Velocidad probable [22-34]	Corresponde al porcentaje de probabilidad durante el mes a que se registren vientos de una potencia entre [22-34] kts
	Velocidad probable [>34]	Corresponde al porcentaje de probabilidad durante el mes a que se registren vientos de una potencia mayor que [34] kts	
	Demanda	Tipo de operación	Define el tipo de operación correspondiente, usualmente: Operación Comercial - Operación Militar - Carga - Otras Operaciones
		Tipo Aeronave	Nombre de la Aeronave a la que representan las operaciones
		Año	Año en que se registraron las operaciones, ya sea por medidas reales, o producto de una proyección
		Cantidad de operaciones	Cantidad de operaciones realizadas por la aeronave correspondiente

Fuente: Alvarez (2020).

# Appendix C

## Factores Índice de Priorización

Tabla C.1: Factor de Operaciones.

Aeropuerto/Aeródromo	Siglas	Despegues Totales Anuales	Logaritmo Natural	%	FO
Mocopulli	SCPQ	908	6.81	4.76	0.98
Mataverí	SCIP	1,091	6.99	4.89	0.97
Pichoy	SCVD	1,955	7.58	5.3	0.95
Desierto de Atacama	SCAT	4,367	8.38	5.86	0.92
Balmaceda	SCBA	4,405	8.39	5.86	0.92
Chacalluta	SCAR	5,773	8.66	6.05	0.91
Cañal Bajo	SCJO	5,931	8.69	6.07	0.91
La Araucanía	SCQP	7,860	8.97	6.27	0.9
El Loa	SCCF	10,228	9.23	6.45	0.89
La Florida	SCSE	11,317	9.33	6.52	0.89
Pte. Carlos Ibáñez del Campo	SCCI	12,214	9.41	6.58	0.89
Diego Aracena	SCDA	14,476	9.58	6.7	0.88
El Tepual	SCTE	15,856	9.67	6.76	0.88
Carnet Sur	SCIE	16,981	9.74	6.81	0.88
Andrés Sabella	SCFA	17,482	9.77	6.83	0.87
Arturo Merino Benítez	SCEL	141,890	11.86	8.29	0.8

Fuente: (Rojas, 2017).

Tabla C.2: Factor Rama.

<b>Rama</b>	<b>Descripción</b>	<b>FR</b>
Pista	Tiene pista alternativa	0.97
	Tiene rodaje paralelo con aptitud de pista	0.95
	No existe ni pista ni rodaje como alternativa	0.85
Rodaje Paralelo	No tiene aptitud de pista	0.95
	Tiene aptitud de pista	0.9
Otros Rodajes	No tiene ruta alternativa	0.8
	Tiene ruta alternativa	0.95
	No es rodaje comercial	0.98
Plataformas	No es plataforma comercial	0.99
	Plataforma tiene más de 3 puestos	0.95
	Plataforma tiene menos de 3 puestos	0.8
Márgenes y zona de protección a chorro	Márgenes y zonas a protección a chorro	1

Fuente: Rojas (2017).

Tabla C.3: Factor Secciones Características.

<b>Rama</b>	<b>Descripción</b>	<b>FS</b>
Pista	Sector central de Pista	0.9
	Sectores de borde de Pista	0.93
	Umbrales	0.95
Rodaje Paralelo	Centro	0.9
	Márgenes	1
Otros Rodajes	Centro	0.9
	Márgenes	1
	General	0.99
Plataformas	Sector de puente de embarque	0.9
	Sector sin puente de embarque	0.93
	Calles aeronáuticas	0.98
	General	0.99
Margen y zona de protección a chorro	Margen y zona de protección a chorro	1

Fuente: Rojas (2017).

# Appendix D

## Descripción Base de Datos

Tabla D.1: Compendio resumen, con rangos de valores típicos de base de datos.

Aeropuerto	Ubicación	Zona	Tipo Pavimento	PCI		Espesor	
				min	max	mix	max
Andrés Sabella	Otros Rodajes	Centro	Asfalto	82	99	10	10
Andrés Sabella	Otros Rodajes	Centro	Hormigón	75	100	24	30
Andrés Sabella	Pista	Borde	Asfalto	75	100	10	16
Andrés Sabella	Pista	Centro	Asfalto	74	100	10	16
Andrés Sabella	Pista	Umbrales	Asfalto	83	98	10	10
Andrés Sabella	Pista	Umbrales	Hormigón	66	100	30	44
Andrés Sabella	Plataforma	Calles aeronáutica	Asfalto	82	82	6	6
Andrés Sabella	Plataforma	Calles aeronáutica	Hormigón	100	100	45	45
Andrés Sabella	Plataforma	General	Asfalto	74	74	6	6
Andrés Sabella	Plataforma	General	Hormigón	78	100	30	45
Andrés Sabella	Rodaje Paralelo	Centro	Asfalto	93	100	10	10
Andrés Sabella	Rodaje Paralelo	Centro	Hormigón	77	100	30	44
Arturo Merino Benítez	Pista	Borde	Asfalto	92	100	13	30
Arturo Merino Benítez	Pista	Centro	Asfalto	64	95	13	30
Arturo Merino Benítez	Pista	Umbrales	Asfalto	87	91	10	13
Arturo Merino Benítez	Pista	Umbrales	Hormigón	32	100	30	40
Arturo Merino Benítez	Plataforma	General	Hormigón	40	98	30	46
Arturo Merino Benítez	Rodaje Paralelo	Centro	Asfalto	48	94	10	13
Arturo Merino Benítez	Rodaje Paralelo	Centro	Hormigón	43	100	30	46
Balmaceda	Margen y zona de protección al Chorro	Margen	Asfalto	65	72	7	7
Balmaceda	Margen y zona de protección al Chorro	Zona Protección a Chorro	Asfalto	69	74	7	7
Balmaceda	Otros Rodajes	Centro	Asfalto	36	93	15	15
Balmaceda	Pista	Borde	Asfalto	68	74	10	15
Balmaceda	Pista	Centro	Asfalto	38	73	10	15
Balmaceda	Pista	Umbrales	Asfalto	67	74	10	15
Balmaceda	Plataforma	General	Asfalto	62	81	7	15
Balmaceda	Plataforma	General	Hormigón	80	82	45	45
Carriel Sur	Margen y zona de protección al Chorro	Margen	Asfalto	70	100	5	10

Table D.1 continued from previous page

Aeropuerto	Ubicación	Zona	Tipo Pavimento	PCI		Espesor	
Carriel Sur	Margen y zona de protección al Chorro	Zona Protección a Chorro	Asfalto	42	42	10	10
Carriel Sur	Otros Rodajes	Centro	Asfalto	71	100	10	13
Carriel Sur	Pista	Borde	Asfalto	81	94	8	10
Carriel Sur	Pista	Centro	Asfalto	65	99	10	10
Carriel Sur	Pista	Umbrales	Asfalto	62	100	10	10
Carriel Sur	Plataforma	General	Asfalto	92	92	13	13
Carriel Sur	Plataforma	General	Hormigón	97	98	30	33
Carriel Sur	Rodaje Paralelo	Centro	Asfalto	92	100	10	12
Cañal Bajo / Carlos Hott Siebert	Otros Rodajes	Centro	Asfalto	93	93	6	6
Cañal Bajo / Carlos Hott Siebert	Otros Rodajes	Centro	Hormigón	87	94	30	38
Cañal Bajo / Carlos Hott Siebert	Pista	Borde	Asfalto	92	97	10	20
Cañal Bajo / Carlos Hott Siebert	Pista	Centro	Asfalto	83	87	10	20
Cañal Bajo / Carlos Hott Siebert	Pista	Umbrales	Asfalto	94	95	10	20
Cañal Bajo / Carlos Hott Siebert	Pista	Umbrales	Hormigón	95	95	38	38
Cañal Bajo / Carlos Hott Siebert	Plataforma	General	Hormigón	80	100	24	38
Chacalluta	Margen y zona de protección al Chorro	Margen	Asfalto	25	76	5	5
Chacalluta	Margen y zona de protección al Chorro	Zona Protección a Chorro	Asfalto	80	85	5	5
Chacalluta	Otros Rodajes	Centro	Asfalto	74	95	10	25
Chacalluta	Pista	Borde	Asfalto	78	97	18	18
Chacalluta	Pista	Centro	Asfalto	76	88	18	18
Chacalluta	Pista	Umbrales	Asfalto	74	95	18	24
Chacalluta	Plataforma	General	Asfalto	62	62	5	5
Chacalluta	Plataforma	General	Hormigón	62	97	5	43
Chacalluta	Rodaje Paralelo	Borde	Asfalto	80	83	10	10
Chacalluta	Rodaje Paralelo	Centro	Asfalto	59	94	10	25
Desierto de Atacama	Margen y zona de protección al Chorro	Margen	Asfalto	94	98	5	5
Desierto de Atacama	Otros Rodajes	Centro	Asfalto	90	100	10	10
Desierto de Atacama	Pista	Borde	Asfalto	93	100	10	10
Desierto de Atacama	Pista	Centro	Asfalto	85	100	10	10
Desierto de Atacama	Pista	Umbrales	Asfalto	85	100	10	10
Desierto de Atacama	Plataforma	General	Asfalto	94	98	5	10
Desierto de Atacama	Plataforma	General	Hormigón	95	99	33	33
Desierto de Atacama	Rodaje Paralelo	Centro	Asfalto	96	96	10	10
Diego Aracena	Otros Rodajes	Centro	Asfalto	68	100	4	31
Diego Aracena	Otros Rodajes	Centro	Hormigón	83	99	5	36
Diego Aracena	Otros Rodajes	Margen	Asfalto	60	92	7	7
Diego Aracena	Pista	Borde	Asfalto	56	99	10	15
Diego Aracena	Pista	Centro	Asfalto	87	98	10	15
Diego Aracena	Pista	Centro	Hormigón	77	77	31	31
Diego Aracena	Pista	Margen	Asfalto	52	97	7	7

Table D.1 continued from previous page

Aeropuerto	Ubicación	Zona	Tipo Pavimento	PCI		Espesor	
Diego Aracena	Pista	Umbrales	Asfalto	99	100	36	44
Diego Aracena	Pista	Umbrales	Hormigón	67	96	31	36
Diego Aracena	Pista	Zona Protección a Chorro	Asfalto	28	28	5	5
Diego Aracena	Pista	Borde	Asfalto	98	99	10	15
Diego Aracena	Pista	Centro	Asfalto	98	99	15	36
Diego Aracena	Pista	Centro	Hormigón	98	98	10	10
Diego Aracena	Plataforma	General	Asfalto	58	97	6	44
Diego Aracena	Plataforma	General	Hormigón	76	98	30	36
Diego Aracena	Rodaje Paralelo	Centro	Asfalto	80	88	10	10
Diego Aracena	Rodaje Paralelo	Centro	Hormigón	67	96	28	44
Diego Aracena	Rodaje Paralelo	Margen	Asfalto	64	85	5	7
El Loa	Margen y zona de protección al Chorro	Zona Protección a Chorro	Asfalto	82	92	5	5
El Loa	Otros Rodajes	Centro	Asfalto	95	100	10	10
El Loa	Otros Rodajes	General	Asfalto	82	94	10	10
El Loa	Pista	Borde	Asfalto	60	96	7	10
El Loa	Pista	Centro	Asfalto	77	97	10	10
El Loa	Plataforma	General	Asfalto	85	100	10	10
El Loa	Plataforma	General	Hormigón	97	97	38	38
El Loa	Rodaje Paralelo	Borde	Asfalto	97	97	10	10
El Loa	Rodaje Paralelo	Calles aeronáutica	Asfalto	98	98	10	10
El Loa	Rodaje Paralelo	Centro	Asfalto	86	97	10	10
El Tepual	Otros Rodajes	Centro	Hormigón	79	88	35	35
El Tepual	Pista	Borde	Hormigón	92	93	24	30
El Tepual	Pista	Centro	Hormigón	83	92	24	24
El Tepual	Pista	Umbrales	Hormigón	76	85	30	30
El Tepual	Plataforma	General	Hormigón	71	95	22	34
El Tepual	Rodaje Paralelo	Centro	Hormigón	68	90	30	30
La Araucanía	Margen y zona de protección al Chorro	Margen	Asfalto	98	100	5	5
La Araucanía	Margen y zona de protección al Chorro	Zona Protección a Chorro	Asfalto	93	98	5	5
La Araucanía	Otros Rodajes	Borde	Asfalto	100	100	10	10
La Araucanía	Otros Rodajes	Centro	Asfalto	99	100	10	10
La Araucanía	Pista	Borde	Asfalto	100	100	10	10
La Araucanía	Pista	Centro	Asfalto	97	98	10	10
La Araucanía	Pista	Margen	Asfalto	97	97	5	5
La Araucanía	Pista	Umbrales	Hormigón	98	99	37	37
La Araucanía	Plataforma	General	Asfalto	99	100	10	10
La Araucanía	Plataforma	General	Hormigón	98	99	37	37
La Florida	Otros Rodajes	Calles aeronáutica	Asfalto	97	100	10	10
La Florida	Otros Rodajes	Centro	Asfalto	59	83	10	10
La Florida	Otros Rodajes	General	Asfalto	99	99	10	10
La Florida	Otros Rodajes	Margen	Asfalto	51	56	5	5
La Florida	Pista	Borde	Asfalto	76	83	5	7,5
La Florida	Pista	Centro	Asfalto	87	100	10	10
La Florida	Pista	Umbrales	Asfalto	70	100	5	10
La Florida	Pista	Zona Protección a Chorro	Asfalto	83	90	5	5
La Florida	Plataforma	General	Asfalto	49	100	5	10

Table D.1 continued from previous page

Aeropuerto	Ubicación	Zona	Tipo Pavimento	PCI		Espesor	
La Florida	Plataforma	General	Hormigón	79	97	28	45
Mataverí	Otros Rodajes	Centro	Asfalto	92	99	15	15
Mataverí	Pista	Borde	Asfalto	65	98	10	13
Mataverí	Pista	Centro	Asfalto	90	100	10	13
Mataverí	Pista	Umbrales	Asfalto	91	98	10	13
Mataverí	Pista	Zona Protección a Chorro	Asfalto	42	49	5	5
Mataverí	Plataforma	General	Asfalto	97	100	15	15
Pichoy	Otros Rodajes	Centro	Asfalto	80	91	10	10
Pichoy	Pista	Borde	Asfalto	100	100	15	15
Pichoy	Pista	Borde	Hormigón	86	96	23	23
Pichoy	Pista	Centro	Asfalto	72	98	10	15
Pichoy	Pista	Umbrales	Asfalto	96	98	10	10
Pichoy	Plataforma	General	Asfalto	92	94	10	10
Presidente Carlos Ibáñez del Campo	Otros Rodajes	Centro	Asfalto	48	93	10	21
Presidente Carlos Ibáñez del Campo	Otros Rodajes	Centro	Hormigón	99	99	38	38
Presidente Carlos Ibáñez del Campo	Pista	Borde	Asfalto	62	100	7	23
Presidente Carlos Ibáñez del Campo	Pista	Centro	Asfalto	54	100	10	23
Presidente Carlos Ibáñez del Campo	Pista	Centro	Hormigón	100	100	33	38
Presidente Carlos Ibáñez del Campo	Pista	Umbrales	Asfalto	97	97	15	15
Presidente Carlos Ibáñez del Campo	Pista	Umbrales	Hormigón	45	100	15	33
Presidente Carlos Ibáñez del Campo	Plataforma	General	Asfalto	53	74	10	15
Presidente Carlos Ibáñez del Campo	Plataforma	General	Hormigón	88	99	31	38
Presidente Carlos Ibáñez del Campo	Rodaje Paralelo	Centro	Hormigón	98	98	38	38

Fuente: Elaboración propia.

# Appendix E

## Base de datos Análisis de Proyecto

Tabla E.1: Datos empleados para modelo de desempeño de pavimento a nivel de proyecto.

Año Evaluación	Sección	Año Construcción	Área (m <sup>2</sup> )	Nomen.	Espesor	Tipo Pavimento	Edad	PCI	PCI t+1
2013	PI-1	2006	1760	ACPC	16	Recapado	7	83	83
2014	PI-1	2006	1760	ACPC	16	Recapado	8	83	82
2015	PI-1	2006	1760	ACPC	16	Recapado	9	82	82
2016	PI-1	2006	1760	ACPC	16	Recapado	10	82	76
2017	PI-1	2006	1760	ACPC	16	Recapado	11	76	74
2018	PI-1	2006	1760	ACPC	16	Recapado	12	74	77
2013	PI-2	2006	2240	ACPC	16	Recapado	7	84	80
2014	PI-2	2006	2240	ACPC	16	Recapado	8	80	75
2016	PI-2	2006	2240	ACPC	16	Recapado	10	85	82
2017	PI-2	2006	2240	ACPC	16	Recapado	11	82	80
2018	PI-2	2006	2240	ACPC	16	Recapado	12	80	80
2013	PI-3	2006	31196	ACPC	16	Recapado	7	95	90
2014	PI-3	2006	31196	ACPC	16	Recapado	8	90	88
2015	PI-3	2006	31196	ACPC	16	Recapado	9	88	85
2016	PI-3	2006	31196	ACPC	16	Recapado	10	85	77
2017	PI-3	2006	31196	ACPC	16	Recapado	11	77	77
2018	PI-3	2006	31196	ACPC	16	Recapado	12	77	79
2013	PI-4	2006	39704	ACPC	16	Recapado	7	92	85
2014	PI-4	2006	39704	ACPC	16	Recapado	8	85	83
2015	PI-4	2006	39704	ACPC	16	Recapado	9	83	84
2016	PI-4	2006	39704	ACPC	16	Recapado	10	84	83
2017	PI-4	2006	39704	ACPC	16	Recapado	11	83	79
2018	PI-4	2006	39704	ACPC	16	Recapado	12	79	79
2013	PI-5	2006	1760	ACPC	11	Recapado	7	100	100
2014	PI-5	2006	1760	ACPC	11	Recapado	8	100	100
2015	PI-5	2006	1760	ACPC	11	Recapado	9	100	100
2016	PI-5	2006	1760	ACPC	11	Recapado	10	100	99
2017	PI-5	2006	1760	ACPC	11	Recapado	11	99	99
2018	PI-5	2006	1760	ACPC	11	Recapado	12	99	99
2013	PI-6	2006	2240	ACPC	11	Recapado	7	100	100

2014	PI-6	2006	2240	ACPC	11	Recapado	8	100	100
2015	PI-6	2006	2240	ACPC	11	Recapado	9	100	100
2016	PI-6	2006	2240	ACPC	11	Recapado	10	100	98
2017	PI-6	2006	2240	ACPC	11	Recapado	11	98	98
2018	PI-6	2006	2240	ACPC	11	Recapado	12	98	98
2013	PI-7	2010	11000	ACPC	11	Recapado	3	99	99
2014	PI-7	2010	11000	ACPC	11	Recapado	4	99	99
2015	PI-7	2010	11000	ACPC	11	Recapado	5	99	99
2016	PI-7	2010	11000	ACPC	11	Recapado	6	99	99
2017	PI-7	2010	11000	ACPC	11	Recapado	7	99	99
2018	PI-7	2010	11000	ACPC	11	Recapado	8	99	99
2013	PI-8	2010	14000	ACPC	11	Recapado	3	100	99
2014	PI-8	2010	14000	ACPC	11	Recapado	4	99	99
2015	PI-8	2010	14000	ACPC	11	Recapado	5	99	99
2016	PI-8	2010	14000	ACPC	11	Recapado	6	99	98
2017	PI-8	2010	14000	ACPC	11	Recapado	7	98	97
2018	PI-8	2010	14000	ACPC	11	Recapado	8	97	96
2013	PI-9	2010	7040	AC	10	Convencional	3	100	100
2014	PI-9	2010	7040	AC	10	Convencional	4	100	100
2015	PI-9	2010	7040	AC	10	Convencional	5	100	100
2016	PI-9	2010	7040	AC	10	Convencional	6	100	100
2017	PI-9	2010	7040	AC	10	Convencional	7	100	100
2018	PI-9	2010	7040	AC	10	Convencional	8	100	100
2013	PI-10	2010	8960	AC	10	Convencional	3	100	100
2014	PI-10	2010	8960	AC	10	Convencional	4	100	100
2015	PI-10	2010	8960	AC	10	Convencional	5	100	100
2016	PI-10	2010	8960	AC	10	Convencional	6	100	100
2017	PI-10	2010	8960	AC	10	Convencional	7	100	100
2018	PI-10	2010	8960	AC	10	Convencional	8	100	100
2013	RA-1	2010	45093	AC	10	Convencional	3	98	98
2014	RA-1	2010	45093	AC	10	Convencional	4	98	97
2015	RA-1	2010	45093	AC	10	Convencional	5	97	97
2016	RA-1	2010	45093	AC	10	Convencional	6	97	98
2017	RA-1	2010	45093	AC	10	Convencional	7	98	98
2018	RA-1	2010	45093	AC	10	Convencional	8	98	97
2013	RA-2	2010	26485	AC	10	Convencional	3	100	100
2014	RA-2	2010	26485	AC	10	Convencional	4	100	100
2015	RA-2	2010	26485	AC	10	Convencional	5	100	100
2016	RA-2	2010	26485	AC	10	Convencional	6	100	100
2017	RA-2	2010	26485	AC	10	Convencional	7	100	100
2018	RA-2	2010	26485	AC	10	Convencional	8	100	99
2013	DE-1	2010	5616	ACPC	10	Recapado	3	93	89
2014	DE-1	2010	5616	ACPC	10	Recapado	4	89	83
2015	DE-1	2010	5616	ACPC	10	Recapado	5	83	82
2016	DE-1	2010	5616	ACPC	10	Recapado	6	82	87
2017	DE-1	2010	5616	ACPC	10	Recapado	7	87	87
2018	DE-1	2010	5616	ACPC	10	Recapado	8	87	84
2013	DD-1	2010	4002	ACPC	10	Recapado	3	99	99
2014	DD-1	2010	4002	ACPC	10	Recapado	4	99	98
2015	DD-1	2010	4002	ACPC	10	Recapado	5	98	97
2016	DD-1	2010	4002	ACPC	10	Recapado	6	97	94
2017	DD-1	2010	4002	ACPC	10	Recapado	7	94	94
2018	DD-1	2010	4002	ACPC	10	Recapado	8	94	92
2013	DC-1	2010	4546	ACPC	10	Recapado	3	95	94

2014	DC-1	2010	4546	ACPC	10	Recapado	4	94	92
2015	DC-1	2010	4546	ACPC	10	Recapado	5	92	91
2016	DC-1	2010	4546	ACPC	10	Recapado	6	91	94
2017	DC-1	2010	4546	ACPC	10	Recapado	7	94	94
2018	DC-1	2010	4546	ACPC	10	Recapado	8	94	92
2013	DB-1	2010	3954	AC	10	Convencional	3	99	97
2014	DB-1	2010	3954	AC	10	Convencional	4	97	97
2015	DB-1	2010	3954	AC	10	Convencional	5	97	96
2016	DB-1	2010	3954	AC	10	Convencional	6	96	97
2017	DB-1	2010	3954	AC	10	Convencional	7	97	98
2018	DB-1	2010	3954	AC	10	Convencional	8	98	97

---

Fuente: Elaboración propia.

# Appendix F

## Base de datos Modelo a Nivel de Red

Tabla F.1: Base de datos empleada para modelo de desempeño a nivel de red.

Aeropuerto	Sección Carac.	PCI	$\Delta t$	Ubicación	Espesor	Edad Pavimento	Tipo Pavimento	Clima	Tránsito	PCI t+dt
SCAR	DB-1	95	2	Otros Rodajes	10	9	Convencional	Seco-Árido	Bajo	92
SCAR	DC-1	81	2	Otros Rodajes	10	9	Convencional	Seco-Árido	Bajo	80
SCAR	DS-1	88	2	Otros Rodajes	25	8	Convencional	Seco-Árido	Bajo	76
SCAR	RA-1	81	2	Rodaje Paralelo	25	9	Convencional	Seco-Árido	Bajo	59
SCAR	RA-2	81	2	Rodaje Paralelo	25	8	Convencional	Seco-Árido	Bajo	65
SCAR	DB-1	95	7	Otros Rodajes	10	9	Convencional	Seco-Árido	Bajo	84
SCAR	DC-1	81	7	Otros Rodajes	10	9	Convencional	Seco-Árido	Bajo	74
SCAR	DB-1	92	5	Otros Rodajes	10	11	Convencional	Seco-Árido	Bajo	84
SCAR	DC-1	80	5	Otros Rodajes	10	11	Convencional	Seco-Árido	Bajo	74
SCAT	PI-2	100	4	Pista	10	10	Convencional	Seco-Árido	Bajo	93
SCAT	PL-2	98	4	Plataforma	10	10	Convencional	Seco-Árido	Bajo	95
SCAT	PL-3	98	4	Plataforma	5	10	Convencional	Seco-Árido	Bajo	95
SCAT	RB-1	100	4	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	100
SCAT	RC-1	100	4	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	92
SCAT	RD-1	100	4	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	98
SCAT	U-17	99	4	Pista	10	10	Convencional	Seco-Árido	Bajo	92
SCAT	U-35	100	4	Pista	10	10	Convencional	Seco-Árido	Bajo	97
SCAT	PI-2	100	5	Pista	10	10	Convencional	Seco-Árido	Bajo	93
SCAT	PL-2	98	5	Plataforma	10	10	Convencional	Seco-Árido	Bajo	95
SCAT	PL-3	98	5	Plataforma	5	10	Convencional	Seco-Árido	Bajo	95
SCAT	RB-1	100	5	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	100
SCAT	RC-1	100	5	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	92
SCAT	RD-1	100	5	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	98
SCAT	U-17	99	5	Pista	10	10	Convencional	Seco-Árido	Bajo	92
SCAT	U-35	100	5	Pista	10	10	Convencional	Seco-Árido	Bajo	96
SCAT	PI-2	100	6	Pista	10	10	Convencional	Seco-Árido	Bajo	93
SCAT	PL-2	98	6	Plataforma	10	10	Convencional	Seco-Árido	Bajo	94
SCAT	PL-3	98	6	Plataforma	5	10	Convencional	Seco-Árido	Bajo	94
SCAT	RB-1	100	6	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	94
SCAT	RC-1	100	6	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	90
SCAT	RD-1	100	6	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	98
SCAT	U-17	99	6	Pista	10	10	Convencional	Seco-Árido	Bajo	91

SCAT	U-35	100	6	Pista	10	10	Convencional	Seco-Árido	Bajo	96
SCAT	PI-1	96	7	Pista	10	10	Convencional	Seco-Árido	Bajo	85
SCAT	PL-2	98	7	Plataforma	10	10	Convencional	Seco-Árido	Bajo	94
SCAT	RB-1	100	7	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	94
SCAT	RD-1	100	7	Otros Rodajes	10	10	Convencional	Seco-Árido	Bajo	96
SCAT	PI-2	93	1	Pista	10	14	Convencional	Seco-Árido	Bajo	93
SCAT	PL-2	95	1	Plataforma	10	14	Convencional	Seco-Árido	Bajo	95
SCAT	PL-3	95	1	Plataforma	5	14	Convencional	Seco-Árido	Bajo	95
SCAT	RB-1	100	1	Otros Rodajes	10	14	Convencional	Seco-Árido	Bajo	100
SCAT	RC-1	92	1	Otros Rodajes	10	14	Convencional	Seco-Árido	Bajo	92
SCAT	RD-1	98	1	Otros Rodajes	10	14	Convencional	Seco-Árido	Bajo	98
SCAT	U-17	92	1	Pista	10	14	Convencional	Seco-Árido	Bajo	92
SCAT	U-35	97	1	Pista	10	14	Convencional	Seco-Árido	Bajo	96
SCAT	PI-2	93	2	Pista	10	14	Convencional	Seco-Árido	Bajo	93
SCAT	PL-2	95	2	Plataforma	10	14	Convencional	Seco-Árido	Bajo	94
SCAT	PL-3	95	2	Plataforma	5	14	Convencional	Seco-Árido	Bajo	94
SCAT	RB-1	100	2	Otros Rodajes	10	14	Convencional	Seco-Árido	Bajo	94
SCAT	RC-1	92	2	Otros Rodajes	10	14	Convencional	Seco-Árido	Bajo	90
SCAT	RD-1	98	2	Otros Rodajes	10	14	Convencional	Seco-Árido	Bajo	98
SCAT	U-17	92	2	Pista	10	14	Convencional	Seco-Árido	Bajo	91
SCAT	U-35	97	2	Pista	10	14	Convencional	Seco-Árido	Bajo	96
SCAT	PL-2	95	3	Plataforma	10	14	Convencional	Seco-Árido	Bajo	94
SCAT	RB-1	100	3	Otros Rodajes	10	14	Convencional	Seco-Árido	Bajo	94
SCAT	RD-1	98	3	Otros Rodajes	10	14	Convencional	Seco-Árido	Bajo	96
SCAT	PI-2	93	1	Pista	10	15	Convencional	Seco-Árido	Bajo	93
SCAT	PL-2	95	1	Plataforma	10	15	Convencional	Seco-Árido	Bajo	94
SCAT	PL-3	95	1	Plataforma	5	15	Convencional	Seco-Árido	Bajo	94
SCAT	RB-1	100	1	Otros Rodajes	10	15	Convencional	Seco-Árido	Bajo	94
SCAT	RC-1	92	1	Otros Rodajes	10	15	Convencional	Seco-Árido	Bajo	90
SCAT	RD-1	98	1	Otros Rodajes	10	15	Convencional	Seco-Árido	Bajo	98
SCAT	U-17	92	1	Pista	10	15	Convencional	Seco-Árido	Bajo	91
SCAT	U-35	96	1	Pista	10	15	Convencional	Seco-Árido	Bajo	96
SCAT	PL-2	95	2	Plataforma	10	15	Convencional	Seco-Árido	Bajo	94
SCAT	RB-1	100	2	Otros Rodajes	10	15	Convencional	Seco-Árido	Bajo	94
SCAT	RD-1	98	2	Otros Rodajes	10	15	Convencional	Seco-Árido	Bajo	96
SCAT	PL-2	94	1	Plataforma	10	16	Convencional	Seco-Árido	Bajo	94
SCAT	RB-1	94	1	Otros Rodajes	10	16	Convencional	Seco-Árido	Bajo	94
SCAT	RD-1	98	1	Otros Rodajes	10	16	Convencional	Seco-Árido	Bajo	96
SCBA	MA-U09	72	2	Margen y zona de protección al Chorro	7	17	Convencional	Templado- Lluvias todo el año	Bajo	70
SCBA	MA-U27	65	2	Margen y zona de protección al Chorro	7	17	Convencional	Templado- Lluvias todo el año	Bajo	65
SCBA	PI-1	45	2	Pista	10	17	Convencional	Templado- Lluvias todo el año	Bajo	38
SCBA	PI-3	73	2	Pista	15	17	Recapado	Templado- Lluvias todo el año	Bajo	63
SCBA	PI-4	74	2	Pista	15	17	Recapado	Templado- Lluvias todo el año	Bajo	72
SCBA	PL-2	81	2	Plataforma	10	13	Convencional	Templado- Lluvias todo el año	Bajo	65
SCBA	RA-1	74	2	Otros Rodajes	15	17	Recapado	Templado- Lluvias todo el año	Bajo	63

SCBA	RB-1	49	2	Otros Rodajes	15	17	Convencional	Templado- Lluvias todo el año	Bajo	36
SCBA	U-09	69	2	Pista	10	17	Convencional	Templado- Lluvias todo el año	Bajo	67
SCBA	ZPCH-09	74	2	Margen y zona de protección al Chorro	7	17	Convencional	Templado- Lluvias todo el año	Bajo	70
SCCF	PL-1	86	7	Plataforma	10	15	Convencional	Seco-Árido	Bajo	85
SCCF	PL-4	100	7	Plataforma	10	0	Convencional	Seco-Árido	Bajo	93
SCCF	PL-5	100	7	Plataforma	10	0	Convencional	Seco-Árido	Bajo	93
SCCF	PL-6	100	7	Plataforma	10	0	Convencional	Seco-Árido	Bajo	97
SCCI	PI-5	100	1	Pista	15	0	Recapado	Templado- Lluvias todo el año	Bajo	100
SCCI	PI-6	100	1	Pista	15	0	Recapado	Templado- Lluvias todo el año	Bajo	97
SCCI	PI-5	100	4	Pista	15	0	Recapado	Templado- Lluvias todo el año	Bajo	60
SCCI	PI-6	100	4	Pista	15	0	Recapado	Templado- Lluvias todo el año	Bajo	75
SCCI	PI-1	94	3	Pista	23	9	Recapado	Templado- Lluvias todo el año	Bajo	70
SCCI	PI-2	95	3	Pista	23	9	Recapado	Templado- Lluvias todo el año	Bajo	86
SCCI	PI-3	82	3	Pista	20	7	Recapado	Templado- Lluvias todo el año	Bajo	55
SCCI	PI-4	84	3	Pista	20	7	Recapado	Templado- Lluvias todo el año	Bajo	78
SCCI	PI-5	100	3	Pista	15	1	Recapado	Templado- Lluvias todo el año	Bajo	60
SCCI	PI-6	97	3	Pista	15	1	Recapado	Templado- Lluvias todo el año	Bajo	75
SCCI	PI-7	81	3	Pista	20	14	Convencional	Templado- Lluvias todo el año	Bajo	54
SCDA	PI-3	98	7	Pista	15	7	Convencional	Seco-Árido	Medio Alto	98
SCDA	PI-4	99	7	Pista	15	7	Convencional	Seco-Árido	Medio Alto	98
SCFA	DB-1	99	1	Otros Rodajes	10	3	Convencional	Seco-Árido	Medio Alto	97
SCFA	DC-1	95	1	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	94
SCFA	DD-1	99	1	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	DE-1	93	1	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	89
SCFA	PI-1	83	1	Pista	16	7	Recapado	Seco-Árido	Medio Alto	83
SCFA	PI-10	100	1	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-2	84	1	Pista	16	7	Recapado	Seco-Árido	Medio Alto	80
SCFA	PI-3	95	1	Pista	16	7	Recapado	Seco-Árido	Medio Alto	90
SCFA	PI-4	92	1	Pista	16	7	Recapado	Seco-Árido	Medio Alto	85
SCFA	PI-5	100	1	Pista	11	7	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-6	100	1	Pista	11	7	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-7	99	1	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	100	1	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-9	100	1	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	98	1	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	98
SCFA	RA-2	100	1	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-1	93	1	Pista	10	3	Convencional	Seco-Árido	Medio Alto	91
SCFA	US-2	98	1	Pista	10	3	Convencional	Seco-Árido	Medio Alto	94
SCFA	DB-1	99	2	Otros Rodajes	10	3	Convencional	Seco-Árido	Medio Alto	97

SCFA	DC-1	95	2	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	92
SCFA	DD-1	99	2	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	98
SCFA	DE-1	93	2	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	83
SCFA	PI-1	83	2	Pista	16	7	Recapado	Seco-Árido	Medio Alto	82
SCFA	PI-10	100	2	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-2	84	2	Pista	16	7	Recapado	Seco-Árido	Medio Alto	75
SCFA	PI-3	95	2	Pista	16	7	Recapado	Seco-Árido	Medio Alto	88
SCFA	PI-4	92	2	Pista	16	7	Recapado	Seco-Árido	Medio Alto	83
SCFA	PI-5	100	2	Pista	11	7	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-6	100	2	Pista	11	7	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-7	99	2	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	100	2	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-9	100	2	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	98	2	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	2	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-1	93	2	Pista	10	3	Convencional	Seco-Árido	Medio Alto	91
SCFA	US-2	98	2	Pista	10	3	Convencional	Seco-Árido	Medio Alto	94
SCFA	DB-1	99	3	Otros Rodajes	10	3	Convencional	Seco-Árido	Medio Alto	96
SCFA	DC-1	95	3	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	91
SCFA	DD-1	99	3	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	97
SCFA	DE-1	93	3	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	82
SCFA	PI-10	100	3	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	95	3	Pista	16	7	Recapado	Seco-Árido	Medio Alto	85
SCFA	PI-5	100	3	Pista	11	7	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-6	100	3	Pista	11	7	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-7	99	3	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	100	3	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-9	100	3	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	98	3	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	3	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-1	93	3	Pista	10	3	Convencional	Seco-Árido	Medio Alto	91
SCFA	US-2	98	3	Pista	10	3	Convencional	Seco-Árido	Medio Alto	93
SCFA	DD-1	99	4	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	94
SCFA	PI-1	83	4	Pista	16	7	Recapado	Seco-Árido	Medio Alto	76
SCFA	PI-10	100	4	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	95	4	Pista	16	7	Recapado	Seco-Árido	Medio Alto	77
SCFA	PI-4	92	4	Pista	16	7	Recapado	Seco-Árido	Medio Alto	83
SCFA	PI-5	100	4	Pista	11	7	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	4	Pista	11	7	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	4	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	100	4	Pista	11	3	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-9	100	4	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	4	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-2	98	4	Pista	10	3	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	99	5	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	94
SCFA	PI-1	83	5	Pista	16	7	Recapado	Seco-Árido	Medio Alto	74
SCFA	PI-10	100	5	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	95	5	Pista	16	7	Recapado	Seco-Árido	Medio Alto	77
SCFA	PI-4	92	5	Pista	16	7	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	100	5	Pista	11	7	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	5	Pista	11	7	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	5	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	100	5	Pista	11	3	Recapado	Seco-Árido	Medio Alto	97
SCFA	PI-9	100	5	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100

SCFA	RA-2	100	5	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-2	98	5	Pista	10	3	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	99	6	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	6	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	92	6	Pista	16	7	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	100	6	Pista	11	7	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	6	Pista	11	7	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	6	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	100	6	Pista	11	3	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	6	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	98	6	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	6	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	98	6	Pista	10	3	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	99	7	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	7	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	92	7	Pista	16	7	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	100	7	Pista	11	7	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	7	Pista	11	7	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	7	Pista	11	3	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	100	7	Pista	11	3	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	7	Pista	10	3	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	98	7	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	7	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	98	7	Pista	10	3	Convencional	Seco-Árido	Medio Alto	83
SCFA	DB-1	99	8	Otros Rodajes	10	3	Convencional	Seco-Árido	Medio Alto	93
SCFA	DD-1	99	8	Otros Rodajes	10	3	Recapado	Seco-Árido	Medio Alto	92
SCFA	RA-1	98	8	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	93
SCFA	RA-2	100	8	Rodaje Paralelo	10	3	Convencional	Seco-Árido	Medio Alto	95
SCFA	DB-1	97	1	Otros Rodajes	10	4	Convencional	Seco-Árido	Medio Alto	97
SCFA	DC-1	94	1	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	92
SCFA	DD-1	99	1	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	98
SCFA	DE-1	89	1	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	83
SCFA	PI-1	83	1	Pista	16	8	Recapado	Seco-Árido	Medio Alto	82
SCFA	PI-10	100	1	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-2	80	1	Pista	16	8	Recapado	Seco-Árido	Medio Alto	75
SCFA	PI-3	90	1	Pista	16	8	Recapado	Seco-Árido	Medio Alto	88
SCFA	PI-4	85	1	Pista	16	8	Recapado	Seco-Árido	Medio Alto	83
SCFA	PI-5	100	1	Pista	11	8	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-6	100	1	Pista	11	8	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-7	99	1	Pista	11	4	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	1	Pista	11	4	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-9	100	1	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	98	1	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	1	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-1	91	1	Pista	10	4	Convencional	Seco-Árido	Medio Alto	91
SCFA	US-2	94	1	Pista	10	4	Convencional	Seco-Árido	Medio Alto	94
SCFA	DB-1	97	2	Otros Rodajes	10	4	Convencional	Seco-Árido	Medio Alto	96
SCFA	DC-1	94	2	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	91
SCFA	DD-1	99	2	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	97
SCFA	DE-1	89	2	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	82
SCFA	PI-10	100	2	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	90	2	Pista	16	8	Recapado	Seco-Árido	Medio Alto	85
SCFA	PI-5	100	2	Pista	11	8	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-6	100	2	Pista	11	8	Recapado	Seco-Árido	Medio Alto	100

SCFA	PI-7	99	2	Pista	11	4	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	2	Pista	11	4	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-9	100	2	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	98	2	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	2	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-1	91	2	Pista	10	4	Convencional	Seco-Árido	Medio Alto	91
SCFA	US-2	94	2	Pista	10	4	Convencional	Seco-Árido	Medio Alto	93
SCFA	DD-1	99	3	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	94
SCFA	PI-1	83	3	Pista	16	8	Recapado	Seco-Árido	Medio Alto	76
SCFA	PI-10	100	3	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	90	3	Pista	16	8	Recapado	Seco-Árido	Medio Alto	77
SCFA	PI-4	85	3	Pista	16	8	Recapado	Seco-Árido	Medio Alto	83
SCFA	PI-5	100	3	Pista	11	8	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	3	Pista	11	8	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	3	Pista	11	4	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	3	Pista	11	4	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-9	100	3	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	3	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-2	94	3	Pista	10	4	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	99	4	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	94
SCFA	PI-1	83	4	Pista	16	8	Recapado	Seco-Árido	Medio Alto	74
SCFA	PI-10	100	4	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	90	4	Pista	16	8	Recapado	Seco-Árido	Medio Alto	77
SCFA	PI-4	85	4	Pista	16	8	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	100	4	Pista	11	8	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	4	Pista	11	8	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	4	Pista	11	4	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	4	Pista	11	4	Recapado	Seco-Árido	Medio Alto	97
SCFA	PI-9	100	4	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	4	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-2	94	4	Pista	10	4	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	99	5	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	5	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	85	5	Pista	16	8	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	100	5	Pista	11	8	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	5	Pista	11	8	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	5	Pista	11	4	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	5	Pista	11	4	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	5	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	98	5	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	5	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	94	5	Pista	10	4	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	99	6	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	6	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	85	6	Pista	16	8	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	100	6	Pista	11	8	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	6	Pista	11	8	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	6	Pista	11	4	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	6	Pista	11	4	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	6	Pista	10	4	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	98	6	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	6	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	94	6	Pista	10	4	Convencional	Seco-Árido	Medio Alto	83
SCFA	DB-1	97	7	Otros Rodajes	10	4	Convencional	Seco-Árido	Medio Alto	93

SCFA	DD-1	99	7	Otros Rodajes	10	4	Recapado	Seco-Árido	Medio Alto	92
SCFA	RA-1	98	7	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	93
SCFA	RA-2	100	7	Rodaje Paralelo	10	4	Convencional	Seco-Árido	Medio Alto	95
SCFA	DB-1	97	1	Otros Rodajes	10	5	Convencional	Seco-Árido	Medio Alto	96
SCFA	DC-1	92	1	Otros Rodajes	10	5	Recapado	Seco-Árido	Medio Alto	91
SCFA	DD-1	98	1	Otros Rodajes	10	5	Recapado	Seco-Árido	Medio Alto	97
SCFA	DE-1	83	1	Otros Rodajes	10	5	Recapado	Seco-Árido	Medio Alto	82
SCFA	PI-10	100	1	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	88	1	Pista	16	9	Recapado	Seco-Árido	Medio Alto	85
SCFA	PI-5	100	1	Pista	11	9	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-6	100	1	Pista	11	9	Recapado	Seco-Árido	Medio Alto	100
SCFA	PI-7	99	1	Pista	11	5	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	1	Pista	11	5	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-9	100	1	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	97	1	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	1	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-1	91	1	Pista	10	5	Convencional	Seco-Árido	Medio Alto	91
SCFA	US-2	94	1	Pista	10	5	Convencional	Seco-Árido	Medio Alto	93
SCFA	DD-1	98	2	Otros Rodajes	10	5	Recapado	Seco-Árido	Medio Alto	94
SCFA	PI-1	82	2	Pista	16	9	Recapado	Seco-Árido	Medio Alto	76
SCFA	PI-10	100	2	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	88	2	Pista	16	9	Recapado	Seco-Árido	Medio Alto	77
SCFA	PI-4	83	2	Pista	16	9	Recapado	Seco-Árido	Medio Alto	83
SCFA	PI-5	100	2	Pista	11	9	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	2	Pista	11	9	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	2	Pista	11	5	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	2	Pista	11	5	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-9	100	2	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	2	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-2	94	2	Pista	10	5	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	98	3	Otros Rodajes	10	5	Recapado	Seco-Árido	Medio Alto	94
SCFA	PI-1	82	3	Pista	16	9	Recapado	Seco-Árido	Medio Alto	74
SCFA	PI-10	100	3	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	88	3	Pista	16	9	Recapado	Seco-Árido	Medio Alto	77
SCFA	PI-4	83	3	Pista	16	9	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	100	3	Pista	11	9	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	3	Pista	11	9	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	3	Pista	11	5	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	3	Pista	11	5	Recapado	Seco-Árido	Medio Alto	97
SCFA	PI-9	100	3	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	3	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-2	94	3	Pista	10	5	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	98	4	Otros Rodajes	10	5	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	4	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	83	4	Pista	16	9	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	100	4	Pista	11	9	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	4	Pista	11	9	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	4	Pista	11	5	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	4	Pista	11	5	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	4	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	97	4	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	4	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	94	4	Pista	10	5	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	98	5	Otros Rodajes	10	5	Recapado	Seco-Árido	Medio Alto	92

SCFA	PI-10	100	5	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	83	5	Pista	16	9	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	100	5	Pista	11	9	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	5	Pista	11	9	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	5	Pista	11	5	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	5	Pista	11	5	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	5	Pista	10	5	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	97	5	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	5	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	94	5	Pista	10	5	Convencional	Seco-Árido	Medio Alto	83
SCFA	DB-1	97	6	Otros Rodajes	10	5	Convencional	Seco-Árido	Medio Alto	93
SCFA	DD-1	98	6	Otros Rodajes	10	5	Recapado	Seco-Árido	Medio Alto	92
SCFA	RA-1	97	6	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	93
SCFA	RA-2	100	6	Rodaje Paralelo	10	5	Convencional	Seco-Árido	Medio Alto	95
SCFA	DD-1	97	1	Otros Rodajes	10	6	Recapado	Seco-Árido	Medio Alto	94
SCFA	PI-10	100	1	Pista	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	85	1	Pista	16	10	Recapado	Seco-Árido	Medio Alto	77
SCFA	PI-5	100	1	Pista	11	10	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	1	Pista	11	10	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	1	Pista	11	6	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	1	Pista	11	6	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-9	100	1	Pista	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	1	Rodaje Paralelo	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-2	93	1	Pista	10	6	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	97	2	Otros Rodajes	10	6	Recapado	Seco-Árido	Medio Alto	94
SCFA	PI-10	100	2	Pista	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	85	2	Pista	16	10	Recapado	Seco-Árido	Medio Alto	77
SCFA	PI-5	100	2	Pista	11	10	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	2	Pista	11	10	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	2	Pista	11	6	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	2	Pista	11	6	Recapado	Seco-Árido	Medio Alto	97
SCFA	PI-9	100	2	Pista	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	2	Rodaje Paralelo	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-2	93	2	Pista	10	6	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	97	3	Otros Rodajes	10	6	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	3	Pista	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-5	100	3	Pista	11	10	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	3	Pista	11	10	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	3	Pista	11	6	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	3	Pista	11	6	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	3	Pista	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	97	3	Rodaje Paralelo	10	6	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	3	Rodaje Paralelo	10	6	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	93	3	Pista	10	6	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	97	4	Otros Rodajes	10	6	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	4	Pista	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-5	100	4	Pista	11	10	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	100	4	Pista	11	10	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	4	Pista	11	6	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	99	4	Pista	11	6	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	4	Pista	10	6	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	97	4	Rodaje Paralelo	10	6	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	100	4	Rodaje Paralelo	10	6	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	93	4	Pista	10	6	Convencional	Seco-Árido	Medio Alto	83

SCFA	DB-1	96	5	Otros Rodajes	10	6	Convencional	Seco-Árido	Medio Alto	93
SCFA	DD-1	97	5	Otros Rodajes	10	6	Recapado	Seco-Árido	Medio Alto	92
SCFA	RA-1	97	5	Rodaje Paralelo	10	6	Convencional	Seco-Árido	Medio Alto	93
SCFA	RA-2	100	5	Rodaje Paralelo	10	6	Convencional	Seco-Árido	Medio Alto	95
SCFA	DD-1	94	1	Otros Rodajes	10	7	Recapado	Seco-Árido	Medio Alto	94
SCFA	PI-1	76	1	Pista	16	11	Recapado	Seco-Árido	Medio Alto	74
SCFA	PI-10	100	1	Pista	10	7	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-3	77	1	Pista	16	11	Recapado	Seco-Árido	Medio Alto	77
SCFA	PI-4	83	1	Pista	16	11	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	99	1	Pista	11	11	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	98	1	Pista	11	11	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	1	Pista	11	7	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	98	1	Pista	11	7	Recapado	Seco-Árido	Medio Alto	97
SCFA	PI-9	100	1	Pista	10	7	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	1	Rodaje Paralelo	10	7	Convencional	Seco-Árido	Medio Alto	100
SCFA	US-2	83	1	Pista	10	7	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	94	2	Otros Rodajes	10	7	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	2	Pista	10	7	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	83	2	Pista	16	11	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	99	2	Pista	11	11	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	98	2	Pista	11	11	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	2	Pista	11	7	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	98	2	Pista	11	7	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	2	Pista	10	7	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	2	Rodaje Paralelo	10	7	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	83	2	Pista	10	7	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	94	3	Otros Rodajes	10	7	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	3	Pista	10	7	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	83	3	Pista	16	11	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	99	3	Pista	11	11	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	98	3	Pista	11	11	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	3	Pista	11	7	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	98	3	Pista	11	7	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	3	Pista	10	7	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	3	Rodaje Paralelo	10	7	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	83	3	Pista	10	7	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	94	4	Otros Rodajes	10	7	Recapado	Seco-Árido	Medio Alto	92
SCFA	RA-2	100	4	Rodaje Paralelo	10	7	Convencional	Seco-Árido	Medio Alto	95
SCFA	DD-1	94	1	Otros Rodajes	10	8	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	1	Pista	10	8	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	79	1	Pista	16	12	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	99	1	Pista	11	12	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	98	1	Pista	11	12	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	1	Pista	11	8	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	97	1	Pista	11	8	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	1	Pista	10	8	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	1	Rodaje Paralelo	10	8	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	83	1	Pista	10	8	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	94	2	Otros Rodajes	10	8	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	2	Pista	10	8	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	79	2	Pista	16	12	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	99	2	Pista	11	12	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	98	2	Pista	11	12	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	2	Pista	11	8	Recapado	Seco-Árido	Medio Alto	99

SCFA	PI-8	97	2	Pista	11	8	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	2	Pista	10	8	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-2	100	2	Rodaje Paralelo	10	8	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	83	2	Pista	10	8	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	94	3	Otros Rodajes	10	8	Recapado	Seco-Árido	Medio Alto	92
SCFA	RA-2	100	3	Rodaje Paralelo	10	8	Convencional	Seco-Árido	Medio Alto	95
SCFA	DD-1	92	1	Otros Rodajes	10	9	Recapado	Seco-Árido	Medio Alto	92
SCFA	PI-10	100	1	Pista	10	9	Convencional	Seco-Árido	Medio Alto	100
SCFA	PI-4	79	1	Pista	16	13	Recapado	Seco-Árido	Medio Alto	79
SCFA	PI-5	99	1	Pista	11	13	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-6	98	1	Pista	11	13	Recapado	Seco-Árido	Medio Alto	98
SCFA	PI-7	99	1	Pista	11	9	Recapado	Seco-Árido	Medio Alto	99
SCFA	PI-8	96	1	Pista	11	9	Recapado	Seco-Árido	Medio Alto	96
SCFA	PI-9	100	1	Pista	10	9	Convencional	Seco-Árido	Medio Alto	100
SCFA	RA-1	97	1	Rodaje Paralelo	10	9	Convencional	Seco-Árido	Medio Alto	97
SCFA	RA-2	99	1	Rodaje Paralelo	10	9	Convencional	Seco-Árido	Medio Alto	99
SCFA	US-2	83	1	Pista	10	9	Convencional	Seco-Árido	Medio Alto	83
SCFA	DD-1	92	2	Otros Rodajes	10	9	Recapado	Seco-Árido	Medio Alto	92
SCFA	RA-1	97	2	Rodaje Paralelo	10	9	Convencional	Seco-Árido	Medio Alto	93
SCFA	RA-2	99	2	Rodaje Paralelo	10	9	Convencional	Seco-Árido	Medio Alto	95
SCFA	DD-1	92	1	Otros Rodajes	10	10	Recapado	Seco-Árido	Medio Alto	92
SCFA	RA-1	97	1	Rodaje Paralelo	10	10	Convencional	Seco-Árido	Medio Alto	93
SCFA	RA-2	99	1	Rodaje Paralelo	10	10	Convencional	Seco-Árido	Medio Alto	95
SCQP	MPI-1	97	1	Margen y zona de protección al Chorro	5	4	Convencional	Templado-Lluvias todo el año	Bajo	97
SCQP	MPL-1	99	1	Margen y zona de protección al Chorro	5	4	Convencional	Templado-Lluvias todo el año	Bajo	99
SCQP	MPL-3	98	1	Margen y zona de protección al Chorro	5	4	Convencional	Templado-Lluvias todo el año	Bajo	98
SCQP	MRB-1	99	1	Margen y zona de protección al Chorro	5	4	Convencional	Templado-Lluvias todo el año	Bajo	99
SCQP	MRC-1	99	1	Margen y zona de protección al Chorro	5	4	Convencional	Templado-Lluvias todo el año	Bajo	99
SCQP	MRPL-1	100	1	Margen y zona de protección al Chorro	5	4	Convencional	Templado-Lluvias todo el año	Bajo	100
SCQP	PI-1	98	1	Pista	10	4	Convencional	Templado-Lluvias todo el año	Bajo	97
SCQP	PI-2	100	1	Pista	10	4	Convencional	Templado-Lluvias todo el año	Bajo	100
SCQP	PL-1	100	1	Plataforma	10	4	Convencional	Templado-Lluvias todo el año	Bajo	99
SCQP	PL-3	99	1	Plataforma	10	4	Convencional	Templado-Lluvias todo el año	Bajo	99
SCQP	RB-1	100	1	Otros Rodajes	10	4	Convencional	Templado-Lluvias todo el año	Bajo	99
SCQP	RC-1	100	1	Otros Rodajes	10	4	Convencional	Templado-Lluvias todo el año	Bajo	100

SCQP	RG-1	100	1	Otros Rodajes	10	4	Convencional	Templado- Lluvias todo el año	Bajo	100
SCQP	RPL-1	100	1	Otros Rodajes	10	4	Convencional	Templado- Lluvias todo el año	Bajo	100
SCQP	ZPCH-01	93	1	Margen y zona de protección al Chorro	5	4	Convencional	Templado- Lluvias todo el año	Bajo	93
SCQP	ZPCH-19	98	1	Margen y zona de protección al Chorro	5	4	Convencional	Templado- Lluvias todo el año	Bajo	98
SCSE	PL-6	100	1	Plataforma	10	0	Convencional	Seco-Árido	Bajo	95
SCSE	PL-6	100	4	Plataforma	10	0	Convencional	Seco-Árido	Bajo	85
SCSE	PL-6	100	6	Plataforma	10	0	Convencional	Seco-Árido	Bajo	77
SCSE	PL-1	90	3	Plataforma	10	16	Convencional	Seco-Árido	Bajo	89
SCSE	PL-6	95	3	Plataforma	10	1	Convencional	Seco-Árido	Bajo	85
SCSE	RB-1	62	3	Otros Rodajes	10	23	Convencional	Seco-Árido	Bajo	59
SCSE	RC-1	83	3	Otros Rodajes	10	23	Convencional	Seco-Árido	Bajo	83
SCSE	ZPCH-12	90	3	Margen y zona de protección al Chorro	5	23	Convencional	Seco-Árido	Bajo	87
SCSE	ZPCH-30	85	3	Margen y zona de protección al Chorro	5	23	Convencional	Seco-Árido	Bajo	83
SCSE	PL-1	90	5	Plataforma	10	16	Convencional	Seco-Árido	Bajo	80
SCSE	PL-6	95	5	Plataforma	10	1	Convencional	Seco-Árido	Bajo	77
SCSE	RB-1	62	5	Otros Rodajes	10	23	Convencional	Seco-Árido	Bajo	59
SCSE	RC-1	83	5	Otros Rodajes	10	23	Convencional	Seco-Árido	Bajo	81
SCSE	ZPCH-12	90	5	Margen y zona de protección al Chorro	5	23	Convencional	Seco-Árido	Bajo	85
SCSE	ZPCH-30	85	5	Margen y zona de protección al Chorro	5	23	Convencional	Seco-Árido	Bajo	83
SCSE	PL-1	90	7	Plataforma	10	16	Convencional	Seco-Árido	Bajo	77
SCSE	PL-1	89	2	Plataforma	10	19	Convencional	Seco-Árido	Bajo	80
SCSE	PL-6	85	2	Plataforma	10	4	Convencional	Seco-Árido	Bajo	77
SCSE	RB-1	59	2	Otros Rodajes	10	26	Convencional	Seco-Árido	Bajo	59
SCSE	RC-1	83	2	Otros Rodajes	10	26	Convencional	Seco-Árido	Bajo	81
SCSE	ZPCH-12	87	2	Margen y zona de protección al Chorro	5	26	Convencional	Seco-Árido	Bajo	85
SCSE	ZPCH-30	83	2	Margen y zona de protección al Chorro	5	26	Convencional	Seco-Árido	Bajo	83
SCSE	PL-1	89	4	Plataforma	10	19	Convencional	Seco-Árido	Bajo	77
SCSE	PL-1	80	2	Plataforma	10	21	Convencional	Seco-Árido	Bajo	77

Fuente: Elaboración propia.

# Appendix G

## Regresiones

Pista-Templado-Lluvias todo el año-Bajo

### Diagnóstico residuos

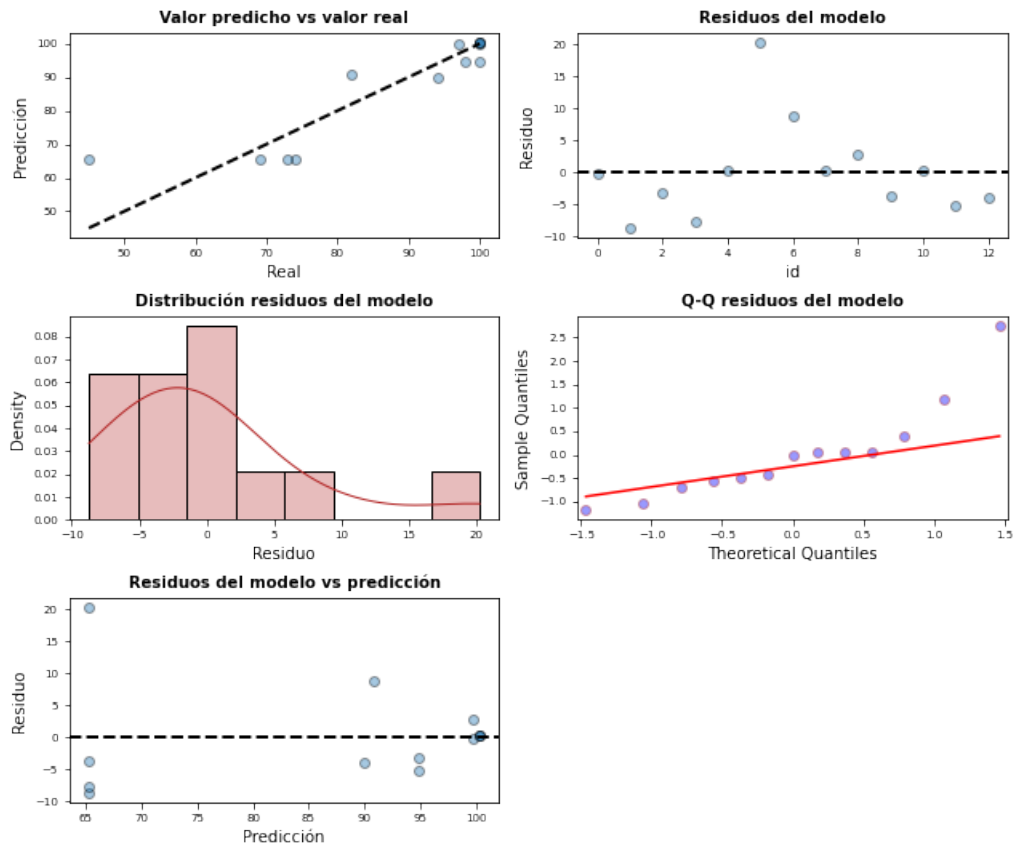


Figura G.1: Diagnóstico Residuos para Pista-Templado-Lluvias todo el año-Bajo

Fuente: Elaboración Propia.

# Plataforma-Seco-Árido

## Diagnóstico residuos

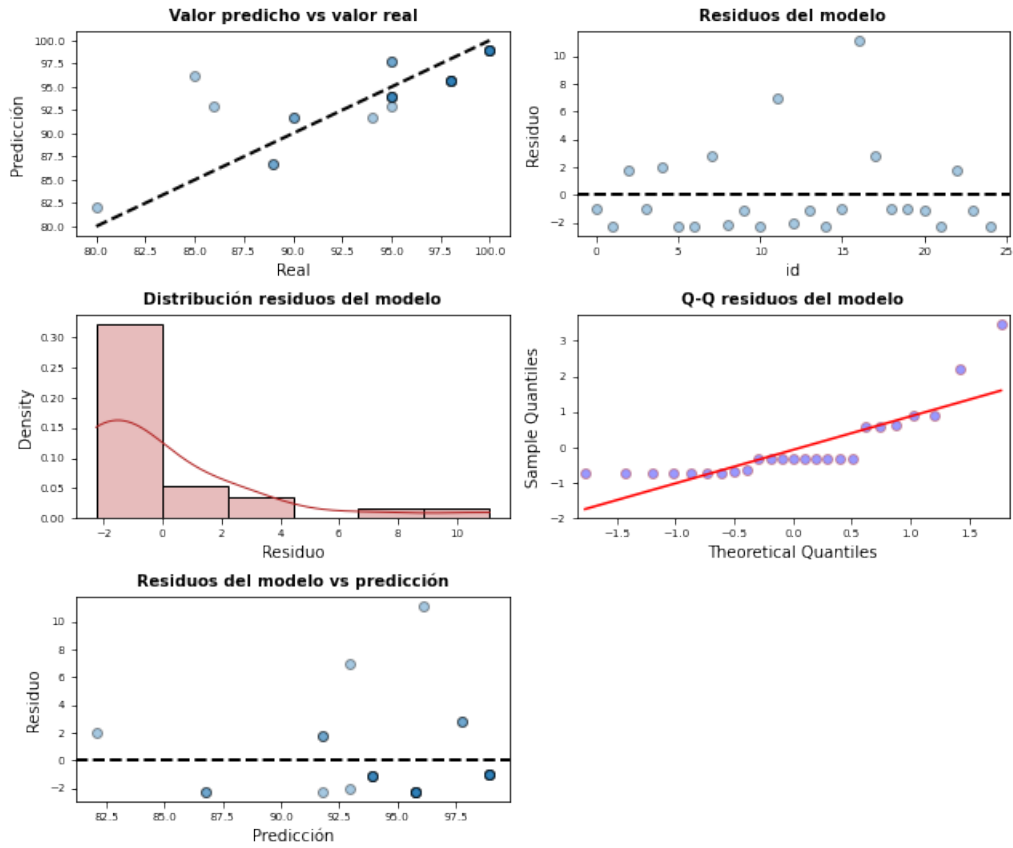


Figura G.2: Diagnóstico Residuos para Plataforma-Seco-Árido  
Fuente: Elaboración Propia.

# Pista-Bajo

## Diagnóstico residuos

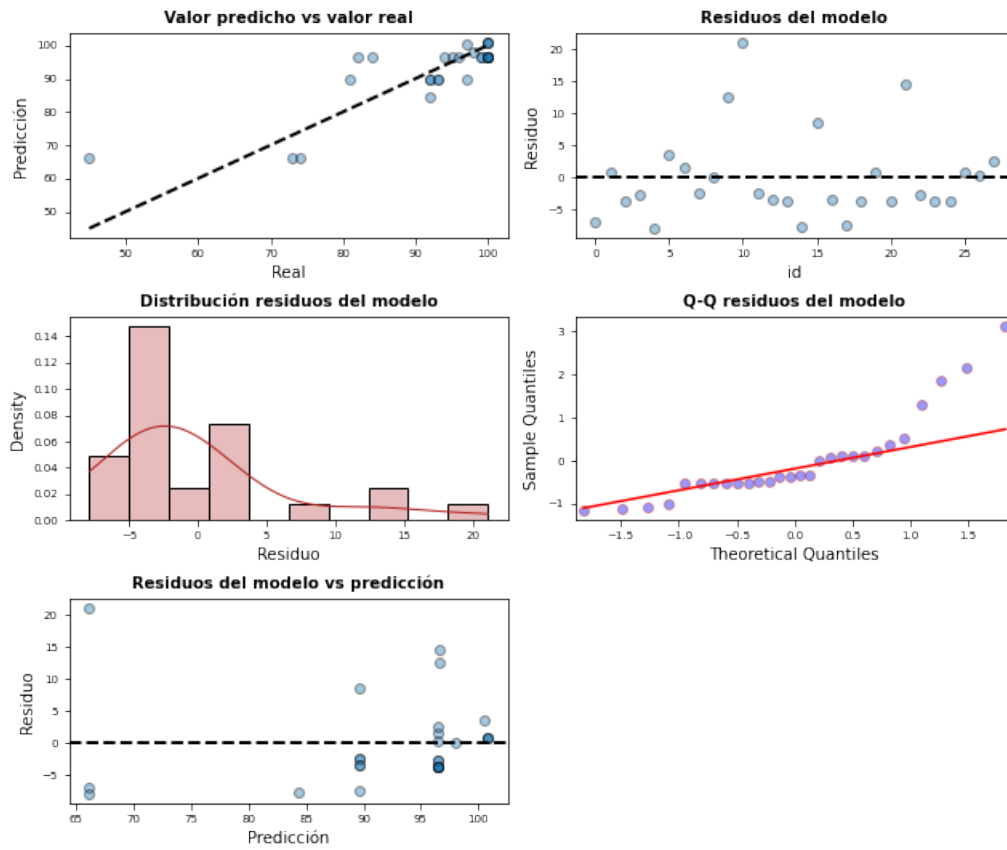


Figura G.3: Diagnóstico Residuos para Pista-Bajo  
Fuente: Elaboración Propia.