UNIVERSIDAD NACIONAL DE HUANCAVELICA

(Creada por ley N° 25265)



FACULTAD DE CIENCIAS DE INGENIERÍA ESCUELA PROFESIONAL DE INGENIERÍA CIVIL HUANCAVELICA

TESIS

Estimación del Índice de Regularidad Internacional en Pavimentos Flexibles Usando Redes Neuronales Artificiales

> DISCIPLINA INGENIERÍA CIVIL

LÍNEA DE INVESTIGACIÓN INFRAESTRUCTURA VIAL

PARA OPTAR EL TÍTULO PROFESIONAL DE: INGENIERO CIVIL

PRESENTADO POR EL BACHILLER: Jhonatan, PAYTÁN ORDOÑEZ

HUANCAVELICA, 01 DE OCTUBRE DEL 2018



UNIVERSIDAD NACIONAL DE HUANCAVELICA

FACULTAD DE CIENCIAS DE INGENIERÍA



ACTA DE SUSTENTACIÓN DE TESIS

En el Auditórium de la Facultad de Ciencias de Ingeniería, a los 18 días del mes de setiembre del año 2018, a horas 3:00 p.m, se reunieron los miembros del Jurado Calificador conformado por los siguientes: **Ing. Omar CABALLERO SÁNCHEZ (PRESIDENTE)**, **M.Sc. Marco Antonio LÓPEZ BARRANTES (SECRETARIO)**, **Arq. Abdón Dante OLIVERA QUINTANILLA (VOCAL)**, designados con Resolución de Consejo de Facultad N° 597-2017-FCI-UNH, de fecha 28 de diciembre del 2017, y ratificados con Resolución de Decano N° 107-2018-FCI-UNH de fecha 29 de agosto del 2018, a fin de proceder con la calificación de la sustentación del informe final de tesis titulado: "ESTIMACIÓN DEL ÍNDICE DE REGULARIDAD INTERNACIONAL EN PAVIMENTOS FLEXIBLES USANDO REDES NEURONALES ARTIFICIALES", presentado por el Bachiller Jhonatan PAYTAN ORDOÑEZ, para optar el Título Profesional de Ingeniero Civil; en presencia del **M.Sc. Iván Arturo AYALA BIZARRO**, Asesor del presente trabajo de tesis. Finalizado la evaluación a horas.....; se invitó al público presente y al sustentante abandonar el recinto. Luego de una amplia deliberación por parte de los Jurados, se llegó al siguiente resultado:

APROBADO



POR WANIMIDAD

DESAPROBADO



En señal de conformidad, firmamos a continuación:

Presidente

Secretario Decano

um Vocal







Agradecimientos

Son muchas las personas que han contribuido en mi formación como ingeniero; familiares, docentes, compañeros de trabajo y amigos, a todos ellos, muchas gracias.

Un agradecimiento especial a M.Sc. Iván Arturo Ayala Bizarro por haber compartido conmigo su interés en la inteligencia artificial y sus aplicaciones en el campo de la ingeniería civil, y por guiar el presente trabajo de investigación.

Agradezco a Ing. Omar Caballero Sánchez, Ing. Carlos Gaspar Paco, Arq. Abdón Dante Olivera Quintanilla e Ing. Marco Antonio López Barrantes, por su colaboración en la revisión de esta tesis.

A la Concesionaria Peruana de Vías Covinca S.A. por permitirme ser parte del grupo de trabajo que elaboró los Estudios Definitivos de Ingeniería del tramo vial Dv. Quilca - Dv. Arequipa - Dv. Matarani - Dv. Moquegua - Dv. Ilo - Tacna - La Concordia. y por permitirme, además, usar información del proyecto para la creación de los modelos neuronales.

Finalmente, agradecer a Javier García, del GILAB-Universitat de Girona y a Marco Antonio y Pedro Pablo Gómez Martín, del departamento de software e inteligencia artificial de la facultad de Informática de la Universidad Complutense de Madrid, en ambos casos por formar parte de una red cada vez mas amplia de divulgadores de conocimiento libre.

Resumen

En las últimas décadas se ha demostrado que una inadecuada gestión de conservación de la infraestructura vial puede ocasionar gastos onerosos a una nación; reduciendo el tiempo de vida útil de las vías, incrementando los costos por operación vehicular e incrementando también el tiempo de traslado de los usuarios. Es por esta razón que es muy importante innovar y contar con herramientas económicas para gestionar adecuadamente nuestras redes viales y contrarrestar posibles restricciones presupuestales. En esta investigación se pretendió construir un modelo basado en Redes Neuronales Artificiales que permita estimar el valor del Índice de Regularidad Internacional en pavimentos flexibles a partir del conocimiento de la condición superficial (fisuras, parches, ahuellamiento, hundimiento, exudación, peladuras y grietas de centro y borde). La construcción del modelo neuronal se hizo con ayuda del software Matlab, para su validación, el modelo neuronal fue usado para estimar los valores del Índice de Regularidad Internacional, tomando como datos de entrada una base diferente a la usada en la etapa de entrenamiento. Estos resultados fueron comparados con los valores de IRI que resultaron de mediciones con el perfilómetro láser. El coeficiente de correlación obtenido fue R=0.365513, el cual refleja una baja relación entre los valores y nos llevó a concluir que las Redes Neuronales Artificiales no tuvieron un buen comportamiento en esta vía específica.

Palabras Clave: Índice de Regularidad Internacional, Índice de Rugosidad Internacional, IRI, pavimento, pavimento flexible, redes neuronales, redes neuronales artificiales.

Abstract

In recent decades it has been shown that inadequate management of road infrastructure conservation can cause onerous expenses to a nation; reducing the useful life of the roads, increasing costs per vehicle operation and also increasing the time of transfer of the users. It is for this reason that it is very important to innovate and have economic tools to properly manage our road networks and counteract possible budget constraints. The aim of this research was to construct a model based on Artificial Neural Networks that allows estimating the value of the International Roughness Index in flexible pavements based on the knowledge of the surface condition (cracks, patches, rutting, subsidence, exudation, peeling and cracks in the center and edge). The construction of the neuronal model was done with the help of the Matlab software, for its validation, the neuronal model was used to estimate the International Roughness Index values, taking as input data a different data to that used in the training stage. These results were compared with the IRI values that resulted from measurements with the laser profilometer. The correlation coefficient obtained was R = 0.365513, which reflects a low relation between the values and led us to conclude that the Artificial Neural Networks did not have a good behavior in this specific road.

Keywords: International Roughness Index, IRI, pavement, flexible pavement, Neural Networks, Artificial Neural Networks.

Índice

A	gradecimientos	IV
Re	lesumen	v
A	bstract	VI
1.	. Problema	1
	1.1. Planteamiento del Problema	1
	1.2. Formulación del Problema	2
	1.2.1. Problema Principal	2
	1.2.2. Problemas Secundarios	2
	1.3. Objetivo de la Investigación	2
	1.3.1. Objetivo General	2
	1.3.2. Objetivos Específicos	2
	1.4. Justificación	3
	1.5. Limitación	3
2.	. Marco Teórico	4
	2.1. Antecedentes	4
	2.2. Bases Teóricas	8
	2.2.1. Índice de Regularidad Internacional	8
	2.2.2. Parámetros de Deterioro o Fallas del Pavimento	10
	2.2.3. Redes Neuronales Artificiales	14
	2.3. Hipótesis	15
	2.4. Identificación de Variables	15
	2.5. Definición Operativa de Variables e Indicadores	16
3.	. Metodología de la Investigación	18
	3.1. Ámbito de Estudio	18
	3.2. Tipo de Investigación	19
	3.3. Nivel de Investigación	20
	3.4. Método de Investigación	20
	3.5. Diseño de Investigación	20
	3.6. Población, Muestra y Muestreo	20

ę	3.7.	Técnicas e Instrumentos de Recolección	21
į	3.8.	Procedimiento de Recolección de Datos	21
e	3.9.	Técnicas de Procesamiento y Análisis de Datos	21
4.]	Mod	lelación y Resultados	23
2	4.1.	Evaluación Superficial	23
4	4.2.	Evaluación Funcional	31
4	4.3.	Modelos Neuronales	34
		4.3.1. Etapa 01	34
		4.3.2. Etapa 02	38
		4.3.3. Etapa 03	47
		4.3.4. Etapa 04	63
Bib	oliog		67

Índice de figuras

2.1.	Modelo del cuarto de carro	9
2.2.	Esquema general del RSP	10
2.3.	Modelo de una Neurona	15
2.4.	Arquitecturas Típicas	16
3.1.	Mapa de ubicación	18
4.1.	porcentaje de área afectada sub tramo 01 $(1/2)$	24
4.2.	porcentaje de área afectada sub tramo $01 (2/2) \ldots \ldots \ldots$	24
4.3.	porcentaje de área afectada sub tramo 02 $(1/3)$	25
4.4.	porcentaje de área afectada sub tramo 02 $(2/3)$	25
4.5.	porcentaje de área afectada sub tramo $02 (3/3) \ldots \ldots \ldots$	26
4.6.	porcentaje de área afectada sub tramo 03 $(1/2)$	26
4.7.	porcentaje de área afectada sub tramo 03 $(2/2)$	27
4.8.	porcentaje de área afectada sub tramo 04 $(1/3)$	27
4.9.	porcentaje de área afectada sub tramo 04 $(2/3)$	28
4.10.	. porcentaje de área afectada sub tramo 04 $(3/3)$	28
4.11.	. IRI sub tramo 01	31
4.12.	IRI sub tramo 02	31
4.13.	. IRI sub tramo 03	32
4.14.	IRI sub tramo 04 $(1/3)$	32
4.15.	IRI sub tramo 04 $(2/3)$	33
4.16.	IRI sub tramo 04 $(3/3)$	33
4.17.	Estructura del modelo neuronal - etapa 01	34
4.18.	Estructura de red 01-01	35
4.19.	Correlación de red 01-01	35
4.20.	Estructura de red 01-02	36
4.21.	Correlación de red 01-02	36
4.22.	Estructura de red 01-03	37
4.23.	. Correlación de red 01-03	37
4.24.	Estructura de red 02-01	39
4.25.	Correlación de red 02-01	39
4.26.	Estructura de red 02-02	40

4.27. Correlación de red 02-02	40
4.28. Estructura de red 02-03	41
4.29. Correlación de red 02-03	41
4.30. Estructura de red 02-04	42
4.31. Correlación de red 02-04	42
4.32. Estructura de red 02-05	43
4.33. Correlación de red 02-05	43
4.34. Estructura de red 02-06	44
4.35. Correlación de red 02-06	44
4.36. Estructura de red 02-07	45
4.37. Correlación de red 02-07	45
4.38. Estructura de red 02-08	46
4.39. Correlación de red 02-08	46
4.40. Correlación IRI Vs Fisuras <2.5mm	48
4.41. Correlación IRI Vs Parches en Buen Estado	48
4.42. Correlación IRI Vs Ahuellamiento <12mm	49
4.43. Correlación IRI Vs Hundimiento <25mm	49
4.44. Correlación IRI Vs Exudación	50
4.45. Correlación IRI Vs Huecos	50
4.46. Correlación IRI Vs Fisuras (2.5 - 5mm)	51
4.47. Correlación IRI Vs Fisuras <2.5mm	51
4.48. Correlación IRI Vs Parches en Mal Estado	52
4.49. Correlación IRI Vs Hundimiento >25mm	52
4.50. Correlación IRI Vs Peladuras	53
4.51. Correlación IRI Vs Grietas long. en centro y bordes	53
4.52. Estructura del modelo neuronal - etapa 03	54
4.53. Estructura de red 03-01	55
4.54. Correlación de red 03-01	55
4.55. Estructura de red 03-02	56
4.56. Correlación de red 03-02	56
4.57. Estructura de red 03-03	57
4.58. Correlación de red 03-03	57
4.59. Estructura de red 03-04	58
4.60. Correlación de red 03-04	58
4.61. Estructura de red 03-05	59
4.62. Correlación de red 03-05	59
4.63. Estructura de red 03-06	60
4.64. Correlación de red 03-06	60
4.65. Estructura de red 03-07 \ldots \ldots \ldots \ldots \ldots \ldots \ldots \ldots \ldots	61
4.66. Correlación de red 03-07	61
4.67. Estructura de red $03-08$	62
4.68. Correlación de red $03-08$	62
4.69. Correlación de validación	63

Índice de Tablas

2.1.	IRI en calzada de concreto asfáltico	10
2.2.	Parámetros de deterioro 1	1
2.3.	Identificación de Variables	16
2.4.	Operacionalización Variable 01	Ι7
2.5.	Operacionalización Variable 02	Ι7
3.1.	Tipo de Investigación	19
3.2.	Diseño de investigación	20
4.1.	Datos de entrada	29
4.2.	Medidas de tendencia y dispersión de daños (1)	30
4.3.	Medidas de tendencia y dispersión de daños (2)	30
4.4.	Medidas de tendencia y dispersión de IRI (1)	33
4.5.	Medidas de tendencia y dispersión de IRI (2)	33
4.6.	Resultados de modelación etapa 01	38
4.7.	Resultados de modelación etapa 02	17
4.8.	Coeficientes de correlación entre Tipos de daños Vs IRI 5	54
4.9.	Resultados de modelación etapa 03	33

Capítulo 1

Problema

1.1. Planteamiento del Problema

Diferentes autores coinciden en que una inadecuada gestión de conservación de la infraestructura vial puede ocasionar gastos onerosos a una nación; reduciendo el tiempo de vida útil de las vías, incrementando los costos por operación vehicular e incrementando también el tiempo de traslado de los usuarios de un lugar a otro. El Banco-Mundial (1994) señaló que invertir 12 mil millones de dólares en obras de mantenimiento durante la década de los ochenta, habría permitido ahorrar 45 mil millones de dólares en costos de reconstrucción de carreteras en África. Asimismo, en el Perú, según el IPE (2008), durante el periodo de 1992 al 2005 se invirtieron 718 millones de dólares en la rehabilitación de carreteras que en la práctica se perdieron porque tal situación hubiera podido evitarse si se destinaba 98 millones de dólares al mantenimiento rutinario y periódico de esas vías.

En pos de una adecuada gestión de conservación de la infraestructura vial, es importante determinar cuándo y cómo realizar las actividades de mantenimiento rutinario y/o periódico de una carretera y para ello las entidades que administran las redes viales toman como referencia distintos indicadores. En el Perú, el Índice de Regularidad Internacional (IRI) es un indicador válido de la condición funcional del pavimento, el cual es determinado, convencionalmente, por equipos que, o son algo económicos pero poco eficientes (como el caso del Merlín) o son eficientes pero muy sofisticados (por ende poco económicos como el caso del Perfilómetro láser).

Alternativamente al uso de equipos mecánicos para determinar el valor del IRI, como los mencionados en el párrafo anterior, han ido surgiendo otros métodos que, bajo ciertas condiciones, podrían ayudar a prescindir de tales equipos; por ejemplo Mubaraki (2016), Prasad et al. (2013) y Amminudin-Bin (2009) construyeron modelos matemáticos basados en regresión estadística que permiten estimar el valor del IRI a partir del conocimiento de la condición superficial, por otro lado, Vidya et al. (2013), Cardona-Villa (2007) y Lin et al. (2003) desarrollaron modelos basados en Redes Neuronales Artificiales (RNA) que al igual que el caso anterior permiten estimar el valor del IRI. Es en este punto en donde el investigador encuentra cierta controversia, debido a que algunas investigaciones mostraron que hay casos en los que las RNA no se desempeñaron como se esperaba y que hay otros en los que las RNA tienen un comportamiento muy bueno. Por este motivo es necesario ampliar el abanico de investigaciones en el campo, a fin de aportar, a la comunidad científica, un nuevo caso para su análisis.

En las próximas secciones se pretende desarrolar un modelo basado en RNA que estime el valor del IRI, partiendo de una base de datos histórica de evaluaciones de las condiciones superficial y funcional de tramos de la vía peruana denominada *Panamericana Sur* (PE-1S), por lo que, surge la necesidad de comparar si los valores de IRI, estimados con el modelo RNA, difieren significativamente de los obtenidos con el Perfilómetro Láser.

1.2. Formulación del Problema

1.2.1. Problema Principal

¿Cómo difiere el valor del Índice de Regularidad Internacional de la vía PE-1S estimado mediante un modelo de Redes Neuronales Artificiales del valor obtenido mediante el Perfilómetro Láser?

1.2.2. Problemas Secundarios

¿Cuáles son los datos de entrada del modelo neuronal?

¿Cuál es la arquitectura del modelo neuronal?

¿Cuál es el algoritmo de aprendizaje del modelo neuronal?

¿Cuál es la función de activación del modelo neuronal?

1.3. Objetivo de la Investigación

1.3.1. Objetivo General

Determinar como difiere el valor del Índice de Regularidad Internacional de la vía PE-1S estimado mediante un modelo de Redes Neuronales Artificiales del valor obtenido mediante el Perfilómetro Láser.

1.3.2. Objetivos Específicos

Determinar cuáles son los datos de entrada del modelo neuronal.

Determinar cuál es la arquitectura del modelo neuronal.

Determinar cuál es el algoritmo de aprendizaje del modelo neuronal.

Determinar cuál es la función de activación del modelo neuronal.

1.4. Justificación

El planteamiento de este proyecto de invetigación responde a la necesidad de contar con herramientas para gestionar adecuadamente nuestras redes viales y de contrarrestar restricciones presupuestales, de algunos gobiernos locales y regionales e incluso de administradores de carreteras privados. Asimismo, la viabilidad del proyecto se basa en la revisión bibliográfica descrita en los siguientes párrafos y ampliada en el capítulo 02.

Estudios orientados a determinar la efectividad de la aplicación de los métodos de las RNA para determinar la relación entre la condición funcional y parámetros de deterioro del pavimento han conducido a resultados distintos entre los investigadores, por ejemplo, Timm and Turochy (2014) concluyeron en su investigación que el modelo basado en Redes Neuronales Artificiales resultó ser no recomendable, mientras que para Saghafi et al. (2009) las RNA tienen un buen comportamiento. La presente investigación sumará un nuevo caso al campo de la ingeniería que permitirá analizar la eficacia de las Redes Neuronales Artificiales en su aplicación a la ingeniería de pavimentos y las posibles razones que influyen en ella.

Es importante mencionar que en una etapa de esta investigación se pretende encontrar el nivel de incidencia de cada parámetro de deterioro superficial del pavimento en el valor del IRI, lo que ayudará a esclarecer el hecho de que cada vez que los investigadores pretendieron relacionar la condición superficial con la condición funcional del pavimento, o dicho de otra manera el IRI con distintos parámetros de deterioro, surgieron algunas diferencias respecto a las consideraciones preliminares, solo por mencionar, para Lin et al. (2003) y Prasad et al. (2013), los baches en el pavimento tienen una incidencia alta en el valor del IRI, en cambio, Mubaraki (2016) encontró evidencia significante para excluir los baches y el ahuellamiento del cálculo del IRI.

Finalmente, se espera que el modelo basado en RNA que se construya sirva de referencia para la entidad que administra la vía estudiada y para cualquier otra (estatal o privada) que tenga restricción de recursos económicos y pueda prescindir parcialmente del uso del perfilómetro láser para determinar el IRI.

1.5. Limitación

La literatura muestra que existen diversos medios mecánicos para determinar el IRI, sin embargo, en esta investigación solo se cosiderará mediciones de IRI con el perfilómetro láser.

Para la construcción del modelo basado en Redes Neuronales Artificiales existen distintos Softwares, sin embargo, en esta investigación únicamente se utilizará el software MATLAB, este software ha sido usado en distintos trabajos de investigación similares y ha mostrado su confiabilidad.

Capítulo 2

Marco Teórico

2.1. Antecedentes

Mubaraki (2016) seleccionó y analizó tramos de la vía que conecta Jeddah y Jazan en Arabia Saudita con el objetivo de investigar la relación entre el Índice de Regularidad Internacional (IRI) y los daños del pavimento (agrietamiento, ahuellamiento y desprendimiento), para tal propósito construyó un modelo basado en Regresión Estadística a partir de información de la condición del pavimento, que recopiló el Ministerio de Transportes de Arabia Saudita empleando el RST (Road Surface Tester). Los resultados del análisis indicaron que existe una relación significante entre IRI y agrietamiento e IRI y desprendimiento a un nivel de confianza del 95%, asimismo, los resultados mostraron que el ahuellamiento no muestra una relación significante con los valores de IRI. El autor concluyó que, si bien existe cierta relación, el IRI no es suficientemente fuerte como para reflejar el deterioro del pavimento, que un incremento de los valores de IRI no significa necesariamente la aceleración del deterioro del pavimento y de manera similar, el deterioro del pavimento no conlleva necesariamente al incremento del valor del IRI del pavimento.

Abiola et al. (2014) indicaron que el objetivo de un sistema de gestión de pavimentos es conseguir ser sistematizado y automatizado, en ese sentido, desarrollaron un modelo de regresión lineal que predice el PCS (Pavement Condition Score) a partir de medidas del Índice de Regularidad Internacional (IRI) del pavimento de la vía expresa Lagos-Ibadan (Nigeria). Como parte de la metodología, colectaron información de densidad y severidad de cuatro tipos de deterioro en pavimentos (baches, grietas, ahuellamiento y parches), y reemplazando estos valores en la fórmula adecuada, recomendada por la Unidad de Evaluación de Pavimentos del Ministerio de Trabajo de Nigeria, obtuvieron el PCS de cada tramo evaluado, asimismo, recolectaron información del IRI, en ambos casos durante cuatro años consecutivos. Los datos de tres años fueron usados para realizar el análisis de regresión mientras que el modelo fue validado con datos del cuarto año. De los resultados, el análisis de varianza para el modelo indica que hay una relación linear fuerte entre los dos índices, pues el coeficiente de determinación obtenido (R^2) es mayor a 0.72, por esta razón concluyeron que la implementación del modelo reduciría los desafíos asociados con la medición visual.

Timm and Turochy (2014) desarrollaron una invetigación con el principal objetivo de desarrollar una metodolgía para actualizar los PCR (Pavement Condition Rating) del ALDOT (Alabama Department of Transportation) para reproducir experiencia previa en gestión de pavimentos utilizando nuevos medios de colección de datos de deterioro. En esta investigación los autores consideraron dos enfoques. El primero fue desarrollar un modelo aplicando Redes Neuronales Artificiales y el segundo consistió en recalibrar el modelo ALDOT PCR existente a través de un análisis de regresión. El entrenamiento de las Redes Neuronales Artificiales y la recalibración PCR se apoyaron en la muestra de datos de comportamiento de pavimento colectados en todo el estado entre el 2009 y el 2010, finalmente la validación de los modelos fue hecha usando medidas de deterioro evaluadas visualmente y automatizadamente en el 2011. De los resultados obtenidos conlcuyeron que la recalibración del modelo original ALDOT PCR es aceptable, por otro lado, el modelo basado en Redes Neuronales Artificiales resultó ser no recomendable para la predicción del PCR.

Vidya et al. (2013) consideran que el IRI es un adecuado indicador del desempeño de una carretera, por lo que, desarrollaron una investigación con el objetivo de estimar el IRI a partir del PCI usando el algoritmo de entrenamiento Levenberg-Marquardt backpropagation. La investigación se realizó en el tramo Trichy-Tanjavur de la vía nacional denominada NH67 en la India, en donde seleccionaron secciones de pavimento en malas condiciones y colectaron información de grietas, ahuellamientos y baches, que fueron los tres parámetros de deterioro superficial usados, adicionalmente colectaron información para calcular el IRI usando el equipo denominado MERLIN. Con esta base de datos construyeron un modelo de arquitectura 3-4-1, apoyado en el programa MATLAB. Los resultados indicaron que el desempeño de las redes neuronales era satisfactorio y confiable para la predicción del IRI. El modelo desarrollado dio un R^2 de 0.86 y un MSE de 0.041.

Prasad et al. (2013) consideran que el Índice de Regularidad Internacional (IRI) expresa adecuadamente la condición funcional de un pavimento y resaltan que es una medida aceptada universalmente, además señalan que el IRI depende de los problemas de deterioro de la superficie del pavimento. En ese sentido enfocaron su investigación en determinar la relación entre el IRI y distintos tipos de deterioros superficiales. Para tal efecto recogieron información de parámetros de deterioro de 136 tramos viales de 50 m de longitud cada uno, que abarcaban 8 carreteras PMGSY (Pradhan Mantri Gram Sadak Yojana) en los distritos de Jhunjhunu y Churu del estado de Rajasthan en la India. Los parámetros de deterioro de pavimento medidos visualmente incluyeron agrietamiento, baches, parches, ahuellamiento, desprendimiento y defectos de borde, mientras que el IRI fue evaluado haciendo uso del equipo denominado Bumbp Integrator. Con la base de datos desarrollaron el modelo de regresión linal múltiple que relacionó el IRI y los parámetros de deterioro del pavimento usando el software SPSS. De los resultados observaron que el valor del R Múltiple fue de 0.815 que significa que la relación entre los valores de IRI observados y predecidos es aceptable.

Amminudin-Bin (2009) trabajó en una investigación cuyo objetivo fue determinar el Índice de Regularidad Internacional (IRI) y el Índice de Serviciabilidad (PSI) de una vía en el interior del campus de la Universidad Técnica de Malasia para luego construir un modelo matemático que permita relacionar tales variables. Para alcanzar dicho objetivo, el autor colectó medidas de IRI y parámetros de deterioro de la superficie en 30 secciones de la vía de 100m cada una, El IRI fue medido usando el Walking Profilometer, mientras los otros parámetros (agrietamiento, ahuellamiento y parches) fueron medidos mediante inspecciones visuales, estos últimos permitieron el cálculo del PSI mediante la aplicación de una fórmula. El análisis estadístico encontró el valor de R^2 igual a 0.564 para la función linear que relaciona el IRI con el PSI, el autor sostuvó que la relación era bastante fuerte, sin embargo consideró que el análisis debería realizarse con una base de datos más amplia a fin de obtener una relación más precisa.

Saghafi et al. (2009) indicaron que las fallas en las juntas transversales de los pavimentos de concreto hidráulico son deterioros influyentes que repercuten considerablemente en el confort del usuario de la vía, señalaron además que muchos son los factores que conllevan a la falla de juntas, entre ellas; el tráfico pesado, la estructura del pavimento, las condiciones climáticas, la edad del pavimento, etc. siendo una de las más importantes, la condición de la capa base. En ese sentido, desarrollaron dos modelos para predecir las fallas en juntas, el primero basado en el método de las Redes Neuronales Artificiales y el segundo basado en la Regresión Linear Multivariable. En ambos casos consideraron la base de datos del proyecto Long Term Pavement Performance (LTPP). De los resultados de la investigación concluveron que las Redes Neuronales Artificiales pueden predecir las fallas de junta en pavimentos de concreto hidráulico con éxito y presición, mostrando un valor de coeficiente de correlación (R^2) igual a 0.94, mientras que el coeficiente de correlación alcanzado por el método de la Regresión Linear Multivariable fue apenas de 0.51, sin embargo, rescatan que este último modelo tiene la ventaja de ser más práctico al momento de interpretar la incidencia de cada variable.

Cardona-Villa (2007) considera que es importante predecir cuándo las vías han llegado a un nivel crítico de rugosidad con el objeto de determinar las acciones correctivas que se deben tomar. Por lo que, expuso en una investigación cómo predecir el IRI en pavimentos flexibles de vías urbanas de la unidad de Medellín, usando la técnica de las Redes Neuronales Artificiales, partiendo de datos de campo tomados por el Sistema de Administración Vial (SAV) de la ciudad, utilizó como variables de entrada el número estructural, la longitud, y los daños en el pavimento que genera deformaciones verticales como el parcheo, el ahuellamiento, las corrugaciones, el abultamiento y los huecos. Como resultado, el modelo desarrollado fue capaz de predecir satisfactoriamente el IRI con un coeficiente de correlación (R^2) de 0.81 en la etapa de validación, mostrando que éste refleja las condiciones de falla de los pavimentos en término de sus deformaciones. En conclusión pudo comprobar que los modelos neuronales fueron capaces de reconocer relaciones complejas y no lineales entre un gran número de variables de entrada y el IRI.

Lin et al. (2003) desarrollaron un análisis de relación entre el Índice de Regularidad Internacional (IRI) y distintos tipos de deterioro del pavimento basado en un modelo back-propagation del método de las Redes Neuronales Artificiales, para ello, haciendo uso de un analizador automático de carreteras, recomendado por el Banco Mundial y la Federal Highway Administration (FHWA), denominado ARAN (Automatic Road Analyzer), colectaron información de 14 parámetros de deterioro del pavimento, además del IRI, en 125 secciones de carreteras de 1Km cada una, incluyendo carreteras provinciales y de condado en Taiwan. La base de datos fue dividida en dos partes; la primera recogió información de 100 secciones de carretera para la fase de entrenamiento y aprendizaje y la segunda recogió información de las 25 secciones restantes para la fase de validación. De los resultados, el IRI pudo ser predecido con presición, los autores alcanzaron un coeficiente de correlación entre el IRI y las variables de deterioro de 0.944, lo que mostró que el IRI pudo reflejar completamente las condiciones de deterioro del pavimento. Asi, concluyeron que era factible usar el IRI como un índice de desempeño del pavimento.

Eldin and Senouci (1995) afirmaron que un modelo basado en Redes Neuronales Artificiales proporcionaría una técnica más ventajosa, al momento de determinar los Índices de Condición de Pavimento, que los modelos matemáticos empleados por los Departamentos de Transporte. Los autores trabajaron en una investigación cuyo objetivo fue desarrollar un modelo basado en Redes Neuronales Artificiales para determinar el Índice de Condición del Pavimento en el Estado de Oregon, para ello aplicaron el algoritmo backpropagation para modelar el sistema de calificación. En la fase de aprendizaje de las Redes Neuronales usaron un grupo amplio de casos de condición de pavimento. Se utilizó un conjunto de 6802 casos para probar la capacidad de generalización del sistema. Esta fase terminó cuando el error se aproximó a 0.022, finalmente, una prueba de hipótesis estadística fue conducido a fin de demostrar las propiedades de generalización y tolerancia del sistema. El estudio concluyó en que el uso de redes neuronales tiene varias ventajas significativas sobre otros métodos de clasificación de la condición del pavimento.

Attoh-Okine (1994) consideró que predecir la progresión de la regularidad durante la vida de diseño del pavimento era muy importante para la toma de desiciones en la gestión, diseño y evaluación de pavimentos. Señaló además que muchos modelos diferentes han sido desarrollados para la caracterización de la progresión de la regularidad en pavimentos flexibles y que a la fecha, los modelos desarrollados para predecir la regularidad se han enfocado principalmente en el desempeño futuro promedio del pavimento. La investigación del autor tuvo por objetivo evaluar las capacidades de las ANN en la predicción de progresión de regularidad en pavimentos flexibles a partir de deformaciones estructurales (número estructural modificado, cargas de tráfico incrementales, grado de agrietamiento y espesor de la capa agrietada y la variación incremental del ahuellamiento), defectos de superficies (cambios en el agrietamiento, parches y baches), y mecanismos ambientales y no relacionados al tráfico (entorno del paviment y tiempo). El autor indicó que las ANN son particularmente adecuadas para tal tarea, ya que se les "enseña", es decir, expuesto los datos, se les permite "aprender" y "decir" cuáles son las respuestas propiadas para las diferentes entradas. De los resultados, el método backpropagation no fue muy exitoso en el proceso de entrenamiento de las ANN con funciones de activación sigmoide, concluyó que la aplicación de ANN en el modelamiento de deterioro de pavimentos es confiable cuando se cuenta con una base de datos amplia.

2.2. Bases Teóricas

2.2.1. Índice de Regularidad Internacional

El Índice de Regularidad Internacional (IRI) es así llamado debido a que es producto del Experimento Internacional de Regularidad de Caminos (IRRE, por sus siglas en inglés), que fue dirigido por equipos de investigación de Brasil, Inglaterra, Francia, Estados Unidos y Bélgica. (Sayers et al., 1986a)

El IRRE se celebró en Brasilia entre mayo y junio de 1982 con el propósito de determinar correlaciones entre los instrumentos de medición de la regularidad y fomentar el desarrollo y la adaptación del IRI para facilitar el intercambio de información. (Sayers et al., 1986b)

2.2.1.1. Definición de IRI

Paterson (1987) define el IRI como un resumen matemático del perfil longitudinal de una superficie de carretera que representa los movimientos verticales en vehículos de pasajeros típicos, inducidos por las irregularidades a una velocidad de desplazamiento de 80 km/h, que afecta tanto a la respuesta del vehículo como a la comodidad de los ocupantes.

El IRI es calculado a partir del modelo cuarto de carro, es decir, una rueda con las características dinámicas asociadas de la suspensión y la masa suspendida, mostrado en la figura 2.1.

Las unidades del IRI son adimensionales, porque es una estadística de pendiente, pero ha sido escalada por un factor de 1.000 de modo que representa m/km, mm/m o pulgadas/1.000 pulgadas. La presentación estándar es, por tanto, de 2,1 m/km IRI, que se reporta generalmente con un decimal.

El MTC (2014) define los valores máximos aceptables de IRI según el tipo de vía y su condición de puesta en servicio, tal como se muestra en la tabla 2.1

2.2.1.2. Medición del IRI

El IRI puede ser medido con equipos topográficos, equipos que miden el perfil longitudinal o equipos que miden los efectos de las irregularidades conocidos como equipos tipo respuesta. Bernucci et al. (2008) referencia que Sayer y Karamihas han empleado ampliamente la siguiente clasificación:

- Evaluación Directa: Usando equipos de clase I (nivel y mira, Dipstick, Perfilómetro TRL, etc.) y clase II (perfilógrafos, equipos con sensores láser, APL francés, etc).
- Evaluación Indirecta: Usa equipos de clase III del tipo "respuesta" (TRL Bump Integrator, Maysmeter, Merlín, etc).



Uno de los equipos con el cual se alcanza un buen nivel de precisión y a la vez un alto rendimiento en las mediciones de rugosidad es el perfilómetro láser de la Cia. Dynatest (RSP), que será el equipo usado en esta investigación (ver figura 2.2), por lo tanto el único que describiremos a continuación.

2.2.1.3. Perfilómetro Láser RSP

de Solminihac T. (2005) ofrece una descripción sintética de este equipo de medición. Este equipo consiste en un VAN con instrumentos que miden los perfiles longitudinales en ambas huellas de rodadura al conducirse a lo largo de un camino. La referencia inercial se consigue con acelerómetros verticales. La distancia hasta la superficie se hace con sensores sin contacto con el pavimento (láser). Las señales del acelerómetro se integran dos veces para determinar la posición del cuerpo del perfilómetro. Cuando esta señal se añade a la señal de posición del seguidor de carretera, se obtiene el perfil.

Parámetro	APC	ASC	CPC	CSC	CTC
IRI Obra Nueva	$2.0 \ IRI_c(1)$	$2.0 IRI_c(1)$	$2.2 IRI_c(2)$	$2.4 \ IRI_c(3)$	$2.8 \ IRI_{c}(5)$
IRI Obra Recapa	$2.5 IRI_c(1)$	$2.5 IRI_c(1)$	$2.7 \ IRI_c(2)$	$2.9 \ IRI_c(3)$	$3.3 IRI_c(5)$
IRI en Servicio	$3.3 IRI_c(1)$	$3.3 IRI_c(1)$	$3.5 IRI_c(2)$	$3.7 \ IRI_c(3)$	$4.1 \ IRI_{c}(5)$
Convenciones		n I II			
APC y ASC, Autop	ista de 1ra y 2d	la clase respecti	ivamente		
CPC, CSC y CTC,	Carretera de 1r	a <mark>, 2da</mark> y <mark>3</mark> ra cla	ase respectivam	ente	
(1) IRI_c a la confial	oilidad de 95%	$IRI_c = IRI_p +$	$-1,\!645 imes ds$		
(2) IRI_c a la confial	oilidad de 90%	$IRI_c = IRI_p +$	-1,282 imes ds		
(3) IRI_c a la confial	oilidad de 85%	$IRI_c = IRI_p +$	$-1,036 \times ds$		
(4) IRI_c a la confial	oilidad de 80%	$IRI_c = IRI_p +$	$-0,842 \times ds$		
(5) IRI_c a la confial	oilidad de 75%	$IRI_c = IRI_p +$	-0,674 imes ds		
$IRI_c = IRI$ caracter	ístico	N. N. /1			
$IRI_p = IRI \text{ promedia}$	io				
ds = desviación está	ndar				
	Fuente:	modificado M	TC (2014)		
			3457		

Tabla 2.1: IRI en calzada de concreto asfáltico

El IRI es calculado de acuerdo con las especificaciones del Banco Mundial. El perfil obtenido cumple con la precisión y el sesgo de un equipo Clase 1 como es definido por la norma ASTM E-950. con mediciones tomadas en intervalos por debajo de los 250 mm con una precisión de menos de 0.1 mm.



Figura 2.2: Esquema general del RSP

2.2.2. Parámetros de Deterioro o Fallas del Pavimento

Para de Solminihac T. (2005) el deterioro del pavimento hace referencia a una serie de manifestaciones en la superficie de la capa de rodadura que hacen de la circulación vehicular menos segura, poco confortable e incrementan los costos de operación.

Los parámetros de deterioro que se tengan que considerar para la evaluación de una vía dependerá del método elegido, cuya selección a su vez responde a los intereses de las entidades administradoras. Entre los métodos más difundidos en el Perú están el del PCI (Pavement Condition Index) y el incluido en el manual de conservación vial del ministerio de transportes y comunicaciones (MTC).

Es preciso mencionar que los tramos de la ruta PE-1S que estudiaremos se encuentran administradas bajo la modalidad de concesión, por lo que, tienen exigencias de niveles de servicio particulares, las cuales están estipuladas en el mismo contrato de concesión. La tabla 2.2 muestra la diferencia de consideraciones entre el contrato de concesión referido y los métodos PCI y MTC.

Concesión PE-1S	MTC
Huecos	Piel de cocodrilo
Fisuras	Fisuras longitudinales
Parches	Deformación
Ahuellamiento	Ahuellamiento
Hundimientos	Rep <mark>araciones o p</mark> archados
Exudación	Peladura y desprendimiento
Peladuras	Baches (Huecos)
Desprendimiento de bordes	Fisuras transversales
Grietas long. centro y bordes	
	*/
	Concesión PE-1S Huecos Fisuras Parches Ahuellamiento Hundimientos Exudación Peladuras Desprendimiento de bordes Grietas long. centro y bordes

Las definiciones de los parámetros de deterioro, presentadas en las siguientes secciones, están basadas en las interpretaciones de la norma ASTM-D-6433 (1999), realizadas y vertidas en el Manual PCI por Varela (2002), en las definiciones del manual de conservación vial, MTC (2014) y en lo señalado en el Contrato de Concesión del Tramo Vial Dv. Quilca - Dv. Arequipa (Repartición) - Dv. Matarani - Dv. Moquegua - Dv. Ilo - Tacna - La Concordia, MTC (2013).

Fuente: Elaboración propia

2.2.2.1. Huecos

Los huecos son depresiones pequeñas en la superficie del pavimento, usualmente con diámetros menores que 0.90 m y con forma de tazón. Por lo general presentan bordes aguzados y lados verticales en cercanías de la zona superior. El crecimiento de los huecos se acelera por la acumulación de agua dentro del mismo. Los huecos se producen cuando el tráfico arranca pequeños pedazos de la superficie del pavimento. La desintegración del pavimento progresa debido a mezclas pobres en la superficie, puntos débiles de la base o la subrasante, o porque se ha alcanzado una condición de piel de cocodrilo de severidad alta. Con frecuencia los huecos son daños asociados a la condición de la estructura y no deben confundirse con desprendimiento o meteorización. Cuando los huecos son producidos por piel de cocodrilo de alta severidad deben registrarse como huecos, no como meteorización.

2.2.2.2. Fisuras

Las fisuras comienzan como pequeñas líneas de rotura para luego ramificarse y acabar formando una malla cerrada. Existen fisuras longitudinales que se desarrollan paralelas al eje del pavimento o a la dirección de construcción, generalmente consecuencia del fenómeno de fatiga de la capa asfáltica sometida a una repetición de cargas superior a la permisible. Asimismo existen fisuras transversales, las cuales se extienden a través del pavimento en ángulos aproximadamente rectos al eje del mismo o a la dirección de construcción, usualmente este tipo de fisuras no están asociadas con cargas sino con retracciones térmicas.

2.2.2.3. Parches

Un parche es un área de pavimento la cual ha sido remplazada con material nuevo para reparar el pavimento existente. Un parche se considera un defecto no importa que tan bien se comporte (usualmente, un área parchada o el área adyacente no se comportan tan bien como la sección original de pavimento). Por lo general se encuentra alguna rugosidad está asociada con este daño.

2.2.2.4. Ahuellamientos

El ahuellamiento es una depresión en la superficie de las huellas de las ruedas. Puede presentarse el levantamiento del pavimento a lo largo de los lados del ahuellamiento, pero, en muchos casos, éste sólo es visible después de la lluvia, cuando las huellas estén llenas de agua. El ahuellamiento se deriva de una deformación permanente en cualquiera de las capas del pavimento o la subrasante, usualmente producida por consolidación o movimiento lateral de los materiales debidos a la carga del tránsito. Un ahuellamiento importante puede conducir a una falla estructural considerable del pavimento.

2.2.2.5. Hundimientos

Los hundimientos son desplazamientos hacia abajo, pequeños y abruptos, de la superficie del pavimento. Las distorsiones y desplazamientos que ocurren sobre grandes áreas del pavimento, causando grandes o largas depresiones en el mismo, se llaman "ondulaciones" (hinchamiento: swelling).

2.2.2.6. Exudación

La exudación es una película de material bituminoso en la superficie del pavimento, la cual forma una superficie brillante, cristalina y reflectora que usualmente llega a ser pegajosa. La exudación es originada por exceso de asfalto en la mezcla, exceso de aplicación de un sellante asfáltico o un bajo contenido de vacíos de aire. Ocurre cuando el asfalto llena los vacíos de la mezcla en medio de altas temperaturas ambientales y entonces se expande en la superficie del pavimento. Debido a que el proceso de exudación no es reversible durante el tiempo frío, el asfalto se acumulará en la superficie.

2.2.2.7. Peladuras

Las peladuras hacen referencia a la desintegración superficial de la carpeta asfáltica debido a la pérdida del ligante bituminoso o del agregado. Las causas más frecuentes suelen ser: defectos en la dosificación, defectos de construcción, agregados defectuosos o efecto de agentes solventes o agua.

2.2.2.8. Desprendimiento de Bordes

El desprendimiento es la pérdida de la superficie del pavimento debida a la pérdida del ligante asfáltico y de las partículas sueltas de agregado. Este daño indica que, o bien el ligante asfáltico se ha endurecido de forma apreciable, o que la mezcla presente es de pobre calidad. Además, el desprendimiento puede ser causado por ciertos tipos de tránsito, por ejemplo, vehículos de orugas. El ablandamiento de la superficie y la pérdida de los agregados debidos al derramamiento de aceites también se consideran como desprendimiento.

2.2.2.9. Grietas Longitudinales en el Centro y Bordes

Son grietas paralelas al eje de la vía, las grietas en el centro suelen tener su origen en una junta de carril del pavimento pobremente construida.

Las grietas de borde generalmente, están a una distancia entre 0.30 y 0.60 m del borde exterior del pavimento. Este daño se acelera por las cargas de tránsito y puede originarse por debilitamiento, debido a condiciones climáticas, de la base o de la subrasante próximas al borde del pavimento.

2.2.3. Redes Neuronales Artificiales

En una revisión de hechos hisóricos, Havkin (1999) señala que las Redes Neuronales Artificiales (RNA) tienen su origen en el trabajo del siguiatra y neuroanatomista McCulloch y del matemático prodigio Pitts en 1943, en donde describieron un cálculo lógico de redes neuronales que unía estudios de neurofisiología y lógica matemática, capaz de calcular cualquier función computable, luego siguieron avances como el desarrollo del Perceptron por Rosenblatt en 1958 (en este introduce un nuevo método de aprendizaje supervisado), el desarrollo de Least Mean-Square (LMS) Algorithm por Widrow y Hoff en 1960 (usado para formular Adaline - Adaptive linear element - alternativo a perceptron), entre otros, hasta que el interés por las RNA decayó en la década de los 70's por razones tecnológicas y de financiamiento y no será hasta la década de los 80's que contribuciones muy importantes en el campo de las RNA hagan que ese interés resurja, tales como la teoría de la resonancia adaptativa establecida por Grossberg en 1980, el nuevo modelo de redes neuronales que construiría Hopfield en 1982 (que llevaría su nombre), el descubrimiento independiente del algoritmo back-propagation por Parker y por LeCun en 1985 y otros. Las RNA ya se han establecido como una materia interdisciplinaria con profundas raíces en la neurociencia, la psicología, las matemáticas, la física y la ingeniería y seguirán creciendo en teoría, diseño y aplicación.

2.2.3.1. Definición de RNA

Las Redes Neuronales Artificiales son sistemas de procesamiento de información que tienen algunas características de comportamiento en común con las redes neuronales biológicas (Fausett, 1994). Una RNA está conformada por una cantidad variable de elementos simples de procesamieto llamados neuronas o nodos, cada neurona está conectada con las demás a través de medios de enlaces de comunicación asociados a un peso, los pesos representan información que utiliza la red para resolver un problema.

2.2.3.2. Modelo Neuronal

Una RNA está caracterizada por su patron de conección entre las neuronas (Arquitectura), el método para determinar los pesos en las conecciones (algoritmo de entrenamiento o aprendizaje) y su función de activación (Fausett, 1994). La figura 2.3 muestra un ejemplo de modelo neuronal simple.

2.2.3.3. Arquitectura de las RNA

La arquitectura de la red hace referencia a la disposición de las neuronas en capas y a los patrones de conección dentro y entre dichas capas (Fausett, 1994). Es típico clasificarlas como redes monocapa y multicapa. Una red monocapa tiene una sola capa de conectores entre las unidades de entrada y salida tal como se ilustra en la imagen 2.4a, mientras que una red multicapa tiene mas de una capa de conectores apoyadas en una o mas capas de neuronas ocultas, la figura 2.4b muestra dos capas de conectores y una de neuronas ocultas entre las unidades de entrada y salida.



2.2.3.4. Aprendizaje o Entrenamiento

El método de ajuste de los pesos en las conecciones es una característica importante en el proceso de aprendizaje, por conveniencia se suele distinguir dos tipos; los supervisados y los no supervisados (Fausett, 1994). el primer grupo presenta una secuencia de vectores de entrenamiento, o patrones, cada uno con un vector de salida objetivo asociado, así los pesos los pesos se ajustan con un algoritmo de aprendizaje. El segundo grupo presenta una secuencia de vectores de entrada pero los vetores objetivo no son especificados.

2.2.3.5. Función de Activación

Una función de activación puede reducir la carga computacional durante el entrenamiento. Las funciones sigmoides (curvas en forma de s) son funciones útiles de activación. La función logística y las funciones tangentes hiperbólicas son las más comunes. especialmente ventajosas para su uso en redes neurales entrenadas por el algoritmo *Backpropagation* (Fausett, 1994).

2.3. Hipótesis

El valor del Índice de Regularidad Internacional de la vía PE-1S, estimado mediante un modelo de Redes Neuronales Artificiales, no difiere significativamente del valor obtenido mediante Perfilómetro Láser.

2.4. Identificación de Variables

La tabla 2.3 muestra las variables identificadas.



2.5. Definición Operativa de Variables e Indicadores

Las tablas 2.4 y 2.5 muestran la operacionalización de las variables.

Sub Variables	Tipo	Escala	Instrumentos
Arquitectura	Cualitativa	Nominal	Matlab
Algoritmo de Aprendizaje	Cualitativa	Nominal	Matlab
Función de Activación	Cualitativa	Nominal	Matlab
Datos de Entrada			
Fisuras(<2.5mm)	Cuantitativa	Continua	Inspección Visual
Fisuras(2.5-5mm)	Cuantitativa	Continua	Inspección Visual
Fisuras(>5mm)	Cuantitativa	Continua	Inspección Visual
Parches en buen estado	Cuantitativa	Continua	Inspección Visual
Parches en mal estado	Cuantitativa	Continua	Inspección Visual
Ahuellamiento <12 mm	Cuantitativa	Continua	Inspección Visual
Ahuellamiento >12 mm	Cuantitativa	Continua	Inspección Visual
Hundimiento <25 mm	Cuantitativa	Continua	Inspección Visual
Hundimiento >25 mm	Cuantitativa	Continua	Inspección Visual
Exudación (B)	Cuantitativa	Continua	Inspección Visual
Exudación (M+A)	Cuantitativa	Continua	Inspección Visual
Reducción del ancho	Cuantitativa	Continua	Inspección Visual
Reducción del Paquete Estructural	Cuantitativa	Continua	Inspección Visual
Huecos	Cuantitativa	Discreta	Inspección Visual
Peladuras	Cuantitativa	Continua	Inspección Visual
Desprendimiento de bordes	Cuantitativa	Continua	Inspección Visual
Grietas long. en centro y borde	Cuantitativa	Continua	Inspección Visual

Tabla 2.4: Operacionalización Variable 01

Fuente: Elaboración propia

Sub Variables	Tipo	Escala	Instrumento
Índice de Regularidad Internacional	Cuantitativa	Contínua	Perfilómetro Láser
Fuente: E	laboración prop	oia	

Capítulo 3

Metodología de la Investigación

3.1. Ámbito de Estudio

El proyecto pertenece a la línea de investigación de Infraestructura Vial, más específicamente a la Gestión de Pavimentos.

La recopilación de datos se hizo en cuatro tramos de la vía clasificada como PE-1S denominada "Panamericana Sur", estos son (ver figura 3.1):



Figura 3.1: Mapa de ubicación Fuente: Elaboración propia

- Dv.Quilca-Dv.Arequipa Km852+335-Km973+884
- Dv.Matarani-Dv.Moquegua Km988+529-Km1146+763

- Dv.Ilo-Tacna Km1184+683-Km1297+993
- Tacna-La Concordia Km1300+080-Km1335+600

Actualmente, los cuatro tramos viales son administrados por la empresa Concesionaria Peruana de Vías COVINCA S.A. bajo la modalidad de concesión.

3.2. Tipo de Investigación

Chavarry (2017) recopiló criterios de diferentes autores y recomienda establecer el tipo de investigación según; el método, la orientación, el enfoque, el tipo de fuente de recolección de datos, y una propia tipología. La tabla 3.1 muestra el resumen de la clasificación de esta investigación.

Clasificación de Acuerdo	Tipo
Al método	Inductiva
A la orientación	Aplicada
Al enfoque	cuantitativo
Con el tipo de fuente de recolección de datos	Retrolectivo
Con la tipología	Correlacional

Tabla 3.1: Tipo de Investigación

Según el método, se trata de una investigación **inductiva** porque se pretende generalizar si el valor del IRI estimado mediante un modelo de Redes Neuronales Artificiales difiere significativamente del valor obtenido mediante el Perfilómetro Láser.

Según su orientación, se trata de una investigación **aplicada** porque está orientada a desarrollar un modelo a partir de la aplicación de investigaciones básicas sobre Redes Neuronales Artificiales.

La investigación ha sido desarrollada bajo el enfoque **cuantitativo**, que tal como lo señalan Hernández Sampieri, et al. (2014) se caracteriza por ser secuencial y probatorio, de orden riguroso; parte de una idea que deriva en objetivos y preguntas de investigación, se establecen las hipótesis y se determinan las variables, se traza un plan para probarlas, medirlas y analizarlas para finalizar en conclusiones.

De acuerdo con el tipo de fuente de recolección de datos, la investigación es **retrolectiva** debido a que, para construir el modelo basado en Redes Neuronales Artificiales y para realizar la contrastación con mediciones del Perfilómetro Láser, se usó datos que ya fueron recogidos en campo entre los años 2013 y 2015, aceptando los métodos e instrumentos usados por los responsables.

De acuerdo con la tipología, la investigación es **correlacional** porque los resultados obtenidos con el modelo basado en Redes Neuronales Artificiales ha sido contrastado con aquellos valores que resulten de mediciones con el Perfilómetro Láser a fin de obtener un coeficiente de determinación R^2 .

3.3. Nivel de Investigación

De acuerdo con Chavarry (2017) podemos considerar que esta investigación se encuentra en el **nivel de estudios descriptivos**, debido a que la pretención fue describir la correlación de dos variables en una circunstancia de tiempo y espacio determinada.

3.4. Método de Investigación

Tal como se señaló en el ítem 3.2, el método corresponde al de una investigación **inductiva** porque se pretende generalizar si el valor del IRI estimado mediante un modelo de Redes Neuronales Artificiales difiere significativamente del valor obtenido mediante el Perfilómetro Láser.

3.5. Diseño de Investigación

Chavarry (2017) señala que los diseños se clasifican según el propósito del estudio, según el número de mediciones y según la cronología de las observaciones. En la Tabla 3.2 se resume la clasificación según los criterios mencionados.

Tabla 3.2: Diseño de investigación

Clasificación según	Diseño
Propósito del estudio	Observacional
Número de mediciones	Transversal
Cronología de las observaciones	Retrospectivo
Fuente: Elaboración propia	

3.6. Población, Muestra y Muestreo

La población está conformada por los cuatro tramos de la vía denominada "Panamericana Sur", que ya se listaron en la sección 3.1:

- Dv.Quilca-Dv.Arequipa Km852+335-Km973+884
- Dv.Matarani-Dv.Moquegua Km988+529-Km1146+763
- Dv.Ilo-Tacna Km1184+683-Km1297+993
- Tacna-La Concordia Km1300+080-Km1335+600

La muestra se obtuvo sobre el total de la población.

3.7. Técnicas e Instrumentos de Recolección

Debido a que la información recabada fue sobre toda la población, el método empleado fue el CENSO.

La técnica consistió en RECOPILAR información de relevamiento de daños sobre el pavimento y mediciones de IRI, realizado entre los años 2013 y 2015 a través de la OBSERVACIÓN.

Para la recolección de información y verificación de niveles de servicio, los instrumentos son los ESTRUCTURADOS que propone el Ministerio de Transportes y Comunicaciones, detallados en las tablas 2.4 y 2.5.

3.8. Procedimiento de Recolección de Datos

Para fines de esta investigación se usará la base de datos recogida entre los años 2013 y 2015 por la concesionaria COVINCA S.A.

Los datos requeridos para desarrollar la investigación son los de la evaluación superficial (parámetros de deterioro) y la evaluación funcional (IRI) del pavimento de los tramos viales referidos en la sección 3.1.

La evaluación superficial, bajo la metodología PCI, se desarrolla recorriendo la vía caminando e identificando visualmente los daños existentes en la calzada, estos daños son registrados en formatos adecuados teniendo en cuenta la clase, severidad y extensión. Los equipos requeridos para realizar esta actividad son; odómetro manual del tipo rueda métrica, cinta métrica, cámara digital y los implementos de seguridad personal como chalecos, cascos y botas.

La evaluación funcional se realiza recorriendo la vía con el perfilómetro láser de la Cia. Dynatest (RSP), El RSP tiene dos componentes primarios; en primer lugar, una unidad de transductores (Rut Bar) equipada con cinco (5) sensores laser y dos (2) acelerómetros y en segundo lugar, un computador, para procesar los datos de los transductores y producir y almacenar los resultados de las mediciones efectuadas.

3.9. Técnicas de Procesamiento y Análisis de Datos

El procesamiento y análisis de la información estuvo repartido en cuatro (04) etapas, las tres primeras concentradas en el proceso de entrenamiento del modelo neuronal y la cuarta orientada al proceso de validación del mismo.

En la primera etapa se construyeron distintos modelos neuronales, con ayuda del software MATLAB, y usando, como datos de entrada, todos los tipos de deterioro encontrados en campo y todos los tramos de la vía.

En la segunda etapa se construyeron modelos neuronales usando, como datos de entrada, todos los tipos de deterioro encontrados en campo, pero esta vez se optó por obviar aquellos tramos que no presentaban deterioro alguno, disminuyendo así la base de datos histórica. En la tercera etapa se analizó la relación entre cada uno de los parámetros de deterioro y el IRI, usando el software Excel, de esta manera se descartó como datos de entrada aquellos parámetros de deterioro que presentaban menor incidencia en el valor del IRI, y a partir de ello se construyeron nuevos modelos neuronales.

En la cuarta etapa se calculó el valor del IRI usando el modelo neuronal que mejores resultados alcanzó y se contrastaron con los obtenidos con el Perfilómetro Láser.



Capítulo 4

Modelación y Resultados

Como se mencionó en el capítulo anterior, el modelo neuronal que permita estimar el valor del IRI fue desarrollado a partir de la base de datos histórica de los parámetros de deterioro e IRI obtenidos en la evaluación superficial y funcional realizada el año 2013, en los tramos de la vía "Panamericana Sur" listados en la sección 3.1. Es importante mencionar que no todos los diferentes tipos de deterioro tienen la misma incidencia sobre el valor del IRI, por lo que, tal como se muestra más adelante, en el item 4.3.3, se prescindió de aquellos parámetros de deterioro que menor influencia mostraban sobre el valor del IRI, obteniéndose un mejor comportamiento de los modelos neuronales que cuando eran incluidos.

En los próximos apartados se muestra el resumen de los resutados de la evaluación superficial, el de la evaluación funcional y el proceso secuencial de la construcción del modelo neuronal.

4.1. Evaluación Superficial

Según el informe TNM (2013), la auscultación visual de la vía, fue llevado a cabo por tres (3) comisiones, cada una conformada por un bachiller y un auxiliar. El bachiller fue el encargado de identificar los tramos de evaluación, los daños existentes en calzada según la metodología PCI y su registro en los formatos respectivos; el auxiliar fue la persona que apoyó en las mediciones de áreas con ayuda del odómetro. El registro de los daños se hicieron teniendo en cuenta la clase, severidad y extensión de los mismos.

En el manual del PCI se identifican 20 tipos de daños a inventariar, las que son: Piel de Cocodrilo, Exudación, Agrietamiento en bloque, Abultamientos/hundimientos, Corrugación, Depresión, Grietas de borde, Grietas reflexión de juntas, Desnivel carril/berma, Grietas long y transversal, Parcheo, Pulimiento de agregados, Huecos, Cruce de vía férrea, Ahuellamiento, Desplazamiento, Grieta parabólica (slippage), Hinchamiento, Desprendimiento, Desgaste.

En los próximos párrafos describiremos de forma resumida los resultados de esta evaluación.


En la figura 4.1 se puede observar que entre el Km 858+000 al Km 862+000 el tipo de daño agrietamiento en bloque tiene el mayor porcentaje de afectación y los daños abultamiento, hundimientos y parcheo tienen presencia desde el Km 863+000 al Km 866+000. En el Km 853+000 el tipo de daño desprendimiento de agregados tiene el mayor porcentaje de afectación.





En la figura 4.2 se observa la presencia de mayores porcentajes de daños, respecto a la anterior, con valores máximos de hasta 100% de área afectada por kilómetro, correspondiente a agrietamiento en bloque entre los Km 924+000, Km 933+000 al Km 934+000, Km 941+000 al Km 943+000, Km 948+000 al Km 950+000 y el Km 958+000 al Km 973+880. El tipo de daño desprendimiento de agregados es el que se registra con mayor frecuencia entre el Km 953+000 al Km 955+000.



En la figura 4.3 se puede observar que entre el Km 1030+000 al Km 1033+000 el tipo de daño agrietamiento en bloque tiene el mayor porcentaje de afectación. Los tipos de daño Abultamiento/Hundimientos y Desnivel Carril/Berma tienen mayor presencia desde el Km 1034+000 al Km 1043+000.



Figura 4.4: porcentaje de área afectada sub tramo 02 (2/3) Fuente: Elaboración propia

En la figura 4.4 se observa que este sector, presenta mayores porcentajes de afectación, con valores cercanos al 100% de área afectada, correspondiente al agrietamiento en bloque en los Km 1094+000 al Km 1096+000. El tipo de daño piel de cocodrilo es el que mayor porcentaje de afectación tiene entre el Km 1062+000 al Km 1065+000. Se observa que el tipo de daño grietas longitudinales y transversales se presenta en porcentajes muy bajos pero constante desde el Km 1048+000 al Km 1066+000 y Km 1074+000 al Km 1089+000.



En la figura 4.5 se puede observar que entre el Km 1113+000 al Km 1146+000 el tipo de daño agrietamiento en bloque tiene el mayor porcentaje de afectación, cercano al 100 %, y el tipo de daño desnivel carril/berma tiene porcentajes de afectación bajos pero constantes desde el Km 1107+000 al Km 1125+000 y del Km 1135+000 al Km 1144+000.





En la figura 4.6 se puede observar que entre el Km 1184+680 al Km 1198+000, Km 1207+000 al Km 1210+000, Km 1220+000 al Km 1244+000 el tipo de daño agrietamiento en bloque tiene el mayor porcentaje de afectación, asimismo, el daño grietas longitudinales y transversales tiene presencia desde el Km 1198+000 al Km 1207+000. Entre el Km 1210+000 al Km 1220+000 el tipo de daño parcheo, desprendimiento de agregados, desnivel carril/berma, grietas longitudinal y transver-



sal, abultamiento/hundimientos, corrugación y huecos, tienen el mayor porcentaje de afectación.

En la figura 4.7 se observa que este sector, a diferencia del anterior, presenta mayores porcentajes de daños, con valores máximos del 97% de área afectada por kilómetro, correspondiente a agrietamiento en bloque. El tipo de daño parcheo es el que se registra con menor frecuencia entre el Km 1254+000 al Km 1255+000, Km 1275+000 al Km 1277+000 y Km 1290+000.



Figura 4.8: porcentaje de área afectada sub tramo 04 (1/3)Fuente: Elaboración propia

En la figura 4.8 se puede observar que entre el Km 1301+000 al Km 1302+000 y Km 1307+000 al Km 1309+880 el tipo de daño agrietamiento en bloque tiene el

mayor porcentaje de afectación. El tipo de daño parcheo, abultamiento/hundimiento son los predominantes entre el Km 1302+000 al Km 1307+000.



En la figura 4.9 se puede observar que entre el Km 1300+080 al Km 1301+000 y Km 1305+000 al Km 1310+000 el tipo de daño agrietamiento en bloque tiene el mayor porcentaje de afectación. El tipo de daño abultamiento/hundimiento tiene 8 % porcentaje de afectación en el Km 1301+000.



Figura 4.10: porcentaje de área afectada sub tramo 04 (3/3)Fuente: Elaboración propia

En la figura 4.10 se puede observar que son dos sectores que presentan afectaciones mayores al 70 % del daño tipo agrietamiento en bloque, estos sectores se encuentran entre las progresivas Km 1309+880 hasta Km 1315+000 y del Km 1324+000 al Km 1335+610. Adicionalmente el sector comprendido entre el Km 1315+000 hasta

el Km 1323+000 presenta fallas puntuales como agrietamientos en bloque, grietas longitudinales y transversales y parcheo; pero el área afectada por estos daños varía entre un 1% y 3%.

Es importante mencionar que al finalizar la evaluación superficial, bajo metodología PCI, se hizo una adaptación de la lista de los tipos de daños encontrados. Esto debido a que los tipos de deterioro que considera evaluar el método PCI difiere de los tipos de deterioro que exige evaluar el contrato de concesión de la vía PE-1S, en el primer caso son veinte (20) tipos de deterioro, mientras que en el segundo caso se trata de nueve (9). La comparación puede verse en la tabla 2.2. La adaptación consistió en agrupar los tipos de daños considerados en la metodología PCI (20) dentro de la lista de daños exigidos en el contrato de concesión (9). Asi por ejemplo, daños como la piel de cocodrilo, el agrietamiento en bloque, las grietas longitudinales y las grietas transversales fueron agrupadas como fisuras.

Para iniciar la construcción de los modelos neuronales, usamos como datos de entrada la lista de nueve (9) tipos de deterioro pero diferenciando su severidad, de esta manera, la cantidad de datos de entrada, estimada inicialmente, fue de quince (15), tal como se muestra en la tabla 4.1.

Tabla 4.1: Datos de entrada

$\mathbf{N}^{\mathbf{o}}$	Tipos de daños considerando su severidad					
01	Fisuras(<2.5mm)	Fisuras(2.5-5mm)	Fisuras(>5mm)			
02	Parches en buen estado	Parches en mal estado				
03	Ahuellamiento <12 mm	Ahuellamiento >12mm				
04	Hundimiento <25mm	Hundimiento >25 mm				
05	Exudación (B)	Exudación (M+A)				
06	Huecos					
07	7 Peladuras					
08	Desprendimiento de bordes					
09	Grietas long. en centro y borde					
Fuente: Elaboración propia						

En las tablas $4.2 ext{ y } 4.3 ext{ presentamos las medidas de tendencia y dispersión de los quince (15) datos de entrada a considerar en la construcción de los modelos neuronales.$

Variables	Media	Mediana	Moda	Desv. Est.	Varianza
Fisuras (<2.5mm)	0. <mark>0</mark> 58	0.037	0.055	0.093	0.009
Parches en buen estado	0.489	0.227	0.014	0.699	0.489
Ahuellamiento $< 12 \text{mm}$	0.147	0.156	0.000	0.103	0.011
Hundimiento <25 mm	0.285	0.052	0.007	0.659	0.435
Exudación (B)	1.394	1.102	2.274	0.951	0.905
Huecos	0.068	0.014	0.014	0.201	0.040
Fisuras (2.5-5mm)	22.775	10.926	11.940	31.450	989.118
Fisuras (>5mm)	1.459	0.898	0.349	1.589	2.524
Parches en mal estado	0.460	0.195	0.000	0.677	0.458
Ahuellamiento >12mm	0.000	0.000	0.000	0.000	0.000
Hundimiento >25 mm	1.957	2.265	3.408	1.251	1.566
Exudación (M+A)	0.000	0.000	0.000	0.000	0.000
Peladuras	1.449	0.365	1.111	2.298	5.282
Desprendimiento de bordes	0.000	0.000	0.000	0.000	0.000
Grietas long. en centro y borde	0.023	0.010	0.010	0.031	0.001

Tabla 4.2: Medidas de tendencia y dispersión de daños $\left(1\right)$

Variables	Curtosis	Coef. Asim.	Rango	Min.	Max.
Fisuras $(<2.5 \text{mm})$	43.832	5.688	1.052	0.000	1.053
Parches en buen estado	14.579	3.231	5.175	0.001	5.176
Ahuellamiento $< 12 \mathrm{mm}$	-1.286	0.172	0.278	0.028	0.306
Hundimiento $<\!25$ mm	32.499	4.964	6.355	0.004	6.359
Exudación (B)	0.406	0.974	3.086	0.326	3.412
Huecos	35.731	5.797	1.447	0.012	1.458
Fisuras (2.5-5mm)	1.608	1.825	105.652	0.001	105.653
Fisuras $(>5mm)$	3.268	1.789	6.770	0.024	6.794
Parches en mal estado	10.210	2.872	3.498	0.001	3.499
Ahuellamiento >12 mm	0.000	0.000	0.000	0.000	0.000
Hundimiento >25 mm	-1.513	-0.210	3.375	0.033	3.408
Exudación (M+A)	0.000	0.000	0.000	0.000	0.000
Peladuras	4.662	2.175	11.111	0.000	11.111
Desprendimiento de bordes	0.000	0.000	0.000	0.000	0.000
Grietas long. en centro y borde	4.481	2.099	0.148	0.000	0.149

Tabla 4.3: Medidas de tendencia y dispersión de daños (2)

Fuente: Elaboración propia

4.2. Evaluación Funcional

Según el informe TNM (2013), el grupo encargado de la medición del Índice de Regularidad Internacional (IRI) estuvo conformado por un ingeniero especializado y un conductor con experiencia en mediciones de este tipo. El conductor es el encargado de manejar el vehículo (Perfilómetro Láser de la Cia. Dynatest - RSP). El ingeniero es el encargado del manejo de la computadora portátil mediante la cual se controla el proceso de medición. El RSP midió el IRI cada 20 m y posteriormente se procesó la información cada 100m.

En los próximos párrafos describiremos de forma resumida los resultados de esta evaluación.



En la figura 4.11 mostramos el comportamiento del IRI en el tramo Dv. Quilca - Dv. Arequipa, cuyos valores varían entre 0.6 y 6.34 m/km, con un valor promedio de 2.41 m/km.



Figura 4.12: IRI sub tramo 02 Fuente: Elaboración propia

En la figura 4.12 mostramos el comportamiento del IRI
en el tramo Dv. Matarani - Dv. Moquegua, cuyos valores varían entre
 0.72y $7.58~{\rm m/km},$ con un valor promedio de
 $1.80~{\rm m/km}.$



En la figura 4.13 mostramos el comportamiento del IRI en el tramo Dv. Ilo-Tacna, cuyos valores varían entre 0.73 y 5.77 m/km, con un valor promedio de 1.78 m/km.



En la figura 4.14 mostramos el comportamiento del IRI en el tramo Tacna - La Concordia (Calzada Derecha), cuyos valores varían entre 1.40 y 6.65 m/km, con un valor promedio de 3.12 m/km.

En la figura 4.15 mostramos el comportamiento del IRI en el tramo Tacna - La Concordia (Calzada Izquierda), cuyos valores varían entre 1.29 y 6.44 m/km, con un valor promedio de 3.07 m/km.

En la figura 4.16 mostramos el comportamiento del IRI en el subtramo de calzada única de Tacna - La Concordia, cuyos valores varían entre 1.09 y 5.75 m/km, con un valor promedio de 2.59 m/km.

Es preciso mencionar que los tramos evaluados presentan resaltos y juntas en los puentes y pontones que afectan negativamente la condición funcional de la vía, para efectos de cálculo estos puntos han sido obviados.

En las tablas 4.4 y 4.5 presentamos las medidas de tendencia y dispersión del IRI a considerar en la etapa de entrenamiento en la construcción de los modelos neuronales.



Tabla 4.4: Medidas de tendencia y dispersión de IRI (1)

Variables	Media	Mediana	Moda	Desv. Est.	Varianza	
IRI	2.068	1.926	1.135	0.797	0.634	
Fuente: Elaboración propia						

Tabla 4.5: Medidas de tendencia y dispersión de IRI (2)

Variables	Curtosis	Coef. Asim.	Rango	Min.	Max.
IRI	0.546	0.859	5.213	0.737	5.950
Fuente: Elaboración propia					

4.3. Modelos Neuronales

La construcción de los modelos neuronales estuvo repartido en cuatro (04) etapas, las tres primeras concentradas en el proceso de entrenamiento del modelo neuronal y la cuarta orientada al proceso de validación del mismo.

4.3.1. Etapa 01

En esta etapa se pretendió usar como datos de entrada, los quince (15) datos señalados en la tabla 4.1, sin embargo, tal como se muestra en las tablas 4.2 y 4.3, no se detectaron daños del tipo Ahuellamiento >12mm, Exudación (M+A) ni Desprendimiento de bordes en ningún tramo de la vía, por lo que la modelación la iniciaremos con los doce (12) restantes tipos de deterioro.

En la figura 4.17 apreciamos un esquema general de la estructura que tendrán los modelos neuronales en esta primera etapa, nótese que los datos de entrada y salida están definidos, quedando pendiente establecer el número de capas ocultas y el número de neuronas que conformarán cada una de ellas.



Figura 4.17: Estructura del modelo neuronal - etapa 01 Fuente: Elaboración propia

La base de datos histórica a emplear en la construcción del modelo neuronal, en esta etapa, está compuesta por 4379 datos, que corresponde a mediciones a lo largo de toda la vía.

El número de capas ocultas y el número de neuronas fueron modificándose tras cada ensayo de prueba y error realizado con el software MATLAB.



Figura 4.19: Correlación de red 01-01 Fuente: Elaboración propia

La primera estructura posee una sola capa oculta y únicamente dos neuronas en dicha capa, tal como se muestra en la figura 4.18. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.28157 (ver figura 4.19), los resultados obtenidos muestran un bajo coeficiente, por lo que corresponde modificar el número de neuronas en la capa oculta.



Figura 4.21: Correlación de red 01-02 Fuente: Elaboración propia

La segunda estructura posee una sola capa oculta y siete (7) neuronas en dicha capa, tal como se muestra en la figura 4.20. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.31669 (ver figura 4.21), los resultados obtenidos muestran un bajo coeficiente.



Figura 4.23: Correlación de red 01-03 Fuente: Elaboración propia

La tercera estructura posee una sola capa oculta y quince (15) neuronas en dicha capa, tal como se muestra en la figura 4.22. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.30776 (ver figura 4.23), los resultados obtenidos muestran un bajo coeficiente.

En la tabla 4.6 se resume las modelaciones hechas en esta etapa.

Red	Arquitectura	F. de Activación	Algoritmo	R^2
01-01	12-2-1	tansig <mark>-</mark> purelin	trainlm	0.28157
01-02	12-7-1	tansig-purelin	trainlm	0.0.31669
01-03	12-15-1	tansig-purelin	trainlm	0.30776

Tabla 4.6: Resultados de modelación	etapa	01
-------------------------------------	-------	----

4.3.2. Etapa 02

En esta segunda etapa usamos, como datos de entrada, los doce (12) tipos de deterioro usados en la primera etapa pero esta vez solo consideramos aquellas secciones de la vía en la que al menos uno de estos tipos de deterioro fue encontrado, de esta manera excluiremos las secciones que no presenten daños.

Excluyendo las secciones que no presentan ningún tipo de daño reducimos la base de datos histórica de 4379 a 1917 datos.

La estructura que tendrán los modelos neuronales en esta segunda etapa será la misma que fue mostrada en la figura 4.17. El número de capas ocultas y el número de neuronas fueron modificándose según el avance de los ensayos.





Fuente: Elaboración propia

La primera estructura posee una sola capa oculta y únicamente dos neuronas en dicha capa, tal como se muestra en la figura 4.24. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.43942 (ver figura 4.25), los resultados obtenidos muestran un índice de regular aceptación, sin embargo en aras de mejorar dicho índice corresponde modificar el número de neuronas en la capa oculta.



Figura 4.27: Correlación de red 02-02 Fuente: Elaboración propia

La segunda estructura posee una sola capa oculta y siete (7) neuronas en dicha capa, tal como se muestra en la figura 4.26. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.46794 (ver figura 4.27), los resultados obtenidos muestran un índice de regular aceptación.



La tercera estructura posee una sola capa oculta y quince (15) neuronas en dicha capa, tal como se muestra en la figura 4.28. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.49196 (ver figura 4.29), los resultados obtenidos muestran un índice de regular aceptación.



La cuarta estructura posee dos capas ocultas y dos (2) neuronas en cada capa, tal como se muestra en la figura 4.30. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.4166 (ver figura 4.31), los resultados obtenidos muestran un índice de regular aceptación.



Fuente: Elaboración propia

La quinta estructura posee dos capas ocultas, la primera capa con dos (2) neuronas y segunda con siete(7), tal como se muestra en la figura 4.32. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.42109 (ver figura 4.33), los resultados obtenidos muestran un índice de regular aceptación.



La sexta estructura posee dos capas ocultas, la primera capa con dos (2) neuronas y segunda con quince (15), tal como se muestra en la figura 4.34. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.44516 (ver figura 4.35), los resultados obtenidos muestran un índice de regular aceptación.



La séptima estructura posee dos capas ocultas, la primera capa con siete (7) neuronas y segunda con quince (15), tal como se muestra en la figura 4.36. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.49354 (ver figura 4.37), los resultados obtenidos muestran un índice de regular aceptación.



La octava estructura posee dos capas ocultas con quince (15) neuronas cada una de ellas, tal como se muestra en la figura 4.38. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.51168 (ver figura 4.39), los resultados obtenidos muestran un índice de regular aceptación.

En la tabla 4.7 se resume las modelaciones hechas en esta etapa.

Arquitectura	F. de Activación	Algoritmo	R^2
12-2-1	tansig-purelin	trainlm	0.43942
12-7-1	tansig-purelin	trainlm	0.46794
12-15-1	tansig-purelin	trainlm	0.49196
12-2-2-1	tansig-tansig-purelin	trainlm	0.4166
12-2-7-1	tansig-tansig-purelin	trainlm	0.42109
12-2-15-1	tansig-tansig-purelin	trainlm	0.44516
12-7-15-1	tansig-tansig-purelin	trainlm	0.49354
12-15-15-1	tansig-tansig-purelin	trainlm	0.51168
	Arquitectura 12-2-1 12-7-1 12-15-1 12-2-2-1 12-2-7-1 12-2-15-1 12-7-15-1 12-15-15-1	ArquitecturaF. de Activación12-2-1tansig-purelin12-7-1tansig-purelin12-15-1tansig-purelin12-2-2-1tansig-tansig-purelin12-2-7-1tansig-tansig-purelin12-2-15-1tansig-tansig-purelin12-7-15-1tansig-tansig-purelin12-15-15-1tansig-tansig-purelin	ArquitecturaF. de ActivaciónAlgoritmo12-2-1tansig-purelintrainlm12-7-1tansig-purelintrainlm12-15-1tansig-purelintrainlm12-2-2-1tansig-tansig-purelintrainlm12-2-7-1tansig-tansig-purelintrainlm12-2-15-1tansig-tansig-purelintrainlm12-7-15-1tansig-tansig-purelintrainlm12-15-15-1tansig-tansig-purelintrainlm12-15-16-1tansig-tansig-purelintrainlm12-15-17-17-17-17-17-17-17-17-17-17-17-17-17-

Tabla 4.7: Resultados de modelación etapa 02

4.3.3. Etapa 03

Debido a que el valor de los coeficientes conseguidos en las etapas 1 y 2 son relativamente bajos, consideramos la necesidad de analizar la incidencia de cada tipo de daño sobre el valor del IRI con la finalidad de excluir, como dato de entrada del modelo neuronal, las de menor incidencia. Para este procedimiento se usó el software EXCEL.

Las figuras 4.40 al 4.51 muestran las gráficas de correlación de cada tipo de daño y el IRI.



Figura 4.41: Correlación IRI V
s Parches en Buen Estado Fuente: Elaboración propia



Figura 4.43: Correlación IRI V
s Hundimiento ${<}25\mathrm{mm}$ Fuente: Elaboración propia



Figura 4.45: Correlación IRI Vs Huecos Fuente: Fuente: Elaboración propia



Figura 4.47: Correlación IRI V
s Fisuras $<\!\!2.5\mathrm{mm}$ Fuente: Elaboración propia



Figura 4.49: Correlación IRI V
s Hundimiento ${>}25\mathrm{mm}$ Fuente: Elaboración propia



Figura 4.51: Correlación IRI Vs Grietas long. en centro y bordes Fuente: Elaboración propia

En la tabla 4.8 se resumen los valores de los coeficientes de correlación que alcanza cada tipo de daño con el IRI.

Tipo de daño	R^2	Coef. correlación R				
Fisuras (<2.5mm)	0.006617545	-0.081348293				
Parches en buen estado	0.047969253	-0.219018843				
Ahuellamiento $< 12 \text{mm}$	0.016028618	0.126604178				
Hundimiento <25 mm	0.014875677	0.121965885				
Exudación (B)	0.166564158	0.408122724				
Huecos	0.004280506	0.065425573				
Fisuras $(2.5-5mm)$	0.033102194	0.181940085				
Fisuras $(>5mm)$	0.038547369	-0.196334839				
Parches en mal estado	0.073046726	0.270271578				
Hundimiento >25 mm	0.401834055	-0.633903822				
Peladuras	0.012747817	0.11290623				
Grietas long. en centro y borde	0.022188783	0.148958 <mark>99</mark> 8				
Fuente: Elaboración propia						

Tabla 4.8: Coeficientes de correlación entre Tipos de daños Vs IRI

Nótese en la tabla 4.8 que los daños del tipo Fisuras (<2.5mm) y Huecos tienen los valores mas bajos de todo el conjunto. Estos dos tipos de daños fueron excluidos como datos de entrada del modelo neuronal en las siguientes estructuras analizadas. De esta manera los datos de entrada se reducen a diez (10) tal como se indica en la figura 4.52, asimismo la base de datos histórica se redujo a 1365 datos.



Figura 4.52: Estructura del modelo neuronal - etapa 03 Fuente: Elaboración propia

A continuación mostramos los resultados de las modelaciones de la tercera etapa.



Figura 4.54: Correlación de red 03-01 Fuente: Elaboración propia

La primera estructura posee una sola capa oculta y únicamente dos neuronas en dicha capa, tal como se muestra en la figura 4.53. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.47576 (ver figura 4.54), los resultados obtenidos muestran un índice de regular aceptación, sin embargo en aras de mejorar dicho índice corresponde modificar el número de neuronas en la capa oculta.



Fuente: Elaboración propia

La segunda estructura posee una sola capa oculta y siete (7) neuronas en dicha capa, tal como se muestra en la figura 4.55. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.50496 (ver figura 4.56), los resultados obtenidos muestran un índice bueno.



Figura 4.58: Correlación de red 03-03 Fuente: Elaboración propia

La tercera estructura posee una sola capa oculta y quince (15) neuronas en dicha capa, tal como se muestra en la figura 4.57. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.5171 (ver figura 4.58), los resultados obtenidos muestran un índice bueno.



La cuarta estructura posee dos capas ocultas y dos (2) neuronas en cada capa, tal como se muestra en la figura 4.59. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.51739 (ver figura 4.60), los resultados obtenidos muestran un índice bueno.





La quinta estructura posee dos capas ocultas, la primera capa con dos (2) neuronas y segunda con siete(7), tal como se muestra en la figura 4.61. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.54054 (ver figura 4.62), los resultados obtenidos muestran un índice bueno.


Fuente: Elaboración propia

La sexta estructura posee dos capas ocultas, la primera capa con dos (2) neuronas y segunda con quince (15), tal como se muestra en la figura 4.63. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.55957 (ver figura 4.64), los resultados obtenidos muestran un índice bueno.



Fuente: Elaboración propia

La séptima estructura posee dos capas ocultas, la primera capa con siete (7) neuronas y segunda con quince (15), tal como se muestra en la figura 4.65. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.57053 (ver figura 4.66), los resultados obtenidos muestran un índice bueno.



Fuente: Elaboración propia

La octava estructura posee dos capas ocultas con quince (15) neuronas cada una de ellas, tal como se muestra en la figura 4.67. El coeficiente de correlación que alcanzamos en la etapa de entrenamiento es de R=0.52818 (ver figura 4.68), los resultados obtenidos muestran un índice bueno.

En la tabla 4.9 se resume las modelaciones hechas en esta etapa.

Red	Arquitectura	F. de Activación	Algoritmo	R^2
03-01	10-2-1	tansig-purelin	trainlm	0.47576
03-02	10-7-1	tansig-purelin	trainlm	0.50496
03-03	10-15-1	tansig-purelin	trainlm	0.5171
03-04	10-2-2-1	tansig-tansig-purelin	trainlm	0.51739
03-05	10-2-7-1	tansig-tansig-purelin	trainlm	0.54054
03-06	10-2-15-1	tansig-tansig-purelin	trainlm	0.55957
03-07	10-7-15-1	tansig-tansig-purelin	trainlm	0.57053
03-08	10-15-15-1	tansig-tansig-purelin	trainlm	0.52818

Tabla 4.9: Resultados de modelación etapa 03

La estructura que ha dado mejores resultados en la etapa de entrenamiento es la Red 03-07 que posee dos capas ocultas, la primera capa con siete (7) neuronas y la segunda con quince (15), cuyo coeficiente de correlación alcanzado es R=0.57053, que representa un buen grado de correlación. Este es el modelo neuronal elegido para el proceso de validación efectuado en la etapa 04 (siguiente item).

4.3.4. Etapa 04

En la cuarta etapa se calculó el valor del IRI usando el modelo neuronal que mejores resultados alcanzó y se contrastaron con los obtenidos con el Perfilómetro Láser.



Figura 4.69: Correlación de validación Fuente: Elaboración propia

De lo mostrado en la figura 4.69 deducimos el coeficiente de correlación R=0.365513,

el cual refleja una baja relación entre los valores de IRI estimados por el modelo neuronal construido y aquelos calculados con el perfilómetro láser.



Conclusiones

Luego de un análisis de relación entre cada tipo de daño del pavimento y el Índice de Regularidad Internacional se determinó usar como datos de entrada del modelo neuronal, aquellos parámetros que presentaban mayor incidencia. Estos fueron diez (10): Fisuras (2.5-5mm), Fisuras (>5mm), Parches en buen estado, Parches en mal estado, Ahuellamiento <12mm, Hundimiento <25mm, Hundimiento >25mm, Exudación (B), Peladuras y Grietas longitudinales en centro y borde.

La arquitectura del modelo neuronal que mejores resultados alcanzó durante la etapa de entrenamiento fue la red 03-07, la cual está conformada por dos capas ocultas, la primera capa con siete (7) neuronas y la segunda con quince (15). El coefciente de correlación alcanzado por el modelo neuronal fue de R=0.57053, que refleja un buen resultado, aunque no suficiente.

El algoritmo de aprendizaje aplicado en este modelo fue Levenberg-Marquardt y la función de activación la sigmoide tangente hiperbólica. En ambos casos su uso fue basado en recomendaciones de investigaciones previas.

El modelo basado en Redes Neuronales Artificiales elegido en la etapa de entrenamiento (red 03-07) fue usado para estimar los valores del Índice de Regularidad Internacional, tomando como datos de entrada una base diferente a la usada en la etapa de entrenamiento. Estos resultados fueron comparados con los valores de IRI que resultaron de mediciones con el perfilómetro láser. El coeficiente de correlación obtenido fue R=0.365513, el cual refleja una baja relación entre los valores, lo que significa que las Redes Neuronales Artificiales no tuvieron un buen comportamiento, concluyendo de esta manera que la hipótesis de la investigación es rechazada y aceptamos la hipótesis nula.

La razón para que el comportamiento de las Redes Neuronales Artificiales no haya sido la esperada probablemente tenga que ver con la influencia de otros factores, tales como el proceso constructivo de la carretera. Consideremos que una carretera construida con algunas deficiencias en el proceso constructivo podría no presentar daños superficiales a temprana edad pero si irregularidades que eleven los valores del IRI, asimismo una carretera construida con un estricto control seguramente evitaría la presencia de daños superficiales e irregularidades, haciendo que se obtenga valores bajos de IRI. Nótese que en ambos casos supuestos no existe presencia de daños superficiales pero diferirían los valores del IRI. Esto nos lleva a concluir que para esta vía específica, la condición superficial no refleja completamente la condición funcional. Es importante mencionar que durante el análisis de relación entre cada tipo de daño del pavimento y el IRI, los daños tipo Huecos fueron uno de los que menor grado de relación mostraron, contradiciendo de alguna manera la primera idea que uno podría hacerse. Al respecto surge la siguiente hipótesis; En la medida que la cantidad de huecos aumenten en una vía, podría aumentar la relación con el valor del IRI, debido a que mientras mas huecos existan sería más complicado que el conductor pueda evitarlos, en cambio, si el número de huecos es menor, el conductor podría evitarlos así no incidiría en el valor del IRI.



Bibliografía

- Abiola, O., Kupolati, W., and Odunfa, S. (2014). Predicting visual pavement score from international roughness index. International Conference on Biological, Civil and Environmental Engineering, pages 78–81.
- Amminudin-Bin, A. L. (2009). Relationship between international roughness index (iri) and present serviceability index (psi). Master's thesis, Faculty of Civil Engineering - Universiti Teknologi Malaysia.
- ASTM-D-6433 (1999). Standard Practice for Roads and Parking Lots Pavement Condition Index Surveys. American Society for Testing and Materials, West Conshohocken, PA 19428-2959, United States.
- Attoh-Okine, N. O. (1994). Predicting roughness progression in flexible pavements using artificial neural networks. 3rd International Conference on Managing Pavements, pages 55–62.
- Banco-Mundial (1994). World Development Report 1994. Infrastructure for Development. The International Bank for Reconstruction and Development - The World Bank, Washington, Estados Unidos.
- Bernucci, L. B., da Motta, L. M. G., Ceratti, J. A. P., and Soares, J. B. (2008). Pavimentação Asfáltica - Formação Básica para Engenheiros. Petrobras - Abeda, Rio de Janeiro, Brasil.
- Cardona-Villa, C. A. (2007). Predicción del Índice de rugosidad internacional en pavimentos flexibles usando redes neuronales artificiales. Master's thesis, Universidad Nacional de Colombia, Medellín.
- Chavarry, C. M. (2017). Metodología de la investigación proyecto de tesis. Presentado en la Escuela de Posgrado.
- de Solminihac T., H. (2005). *Gestión de Infraestructura Vial*. Afaomega Grupo Editor, Colombia.
- Eldin, N. N. and Senouci, A. B. (1995). Use of neural networks for condition rating of jointed concrete pavements. Advances in Engineering Software - Florida International University, pages 133–141.
- Fausett, L. (1994). Fundamentals of Neural Networks. Prentice Hall, New Yersey, Estados Unidos.

- Haykin, S. (1999). Neural Networks a Comprehensive Foundation. Prentice Hall, India.
- IPE (2008). Lecciones de Mantenimiento de Carreteras en el Perú, 1992-2007. Instituto Peruano de Economía.
- Lin, J.-D., Yau, J.-T., and Hsiao, L.-H. (2003). Correlation analysis between international roughness index (iri) and pavement distress by neural network. *Trans*portation Research Board, pages 1–21.
- MTC (2013). Contrato de Concesión del Tramo Vial Desvío Quilca Desvío Arequipa (Repartición) - Desvío Matarani - Desvío Moquegua - Desvío Ilo - Tacna - La Concordia. Proinversión, Lima, Perú.
- MTC (2014). Manual de Carreteras Mantenimiento o Conservación Vial. Ministerio de Transportes y Comunicaciones - Perú, Lima, Perú.
- Mubaraki, M. (2016). Highway subsurface assessment using pavement surface distress and roughness data. *International Journal of Pavement Research and Technology*, pages 393–402.
- Paterson, W. D. (1987). Road Deterioration and Maintenance Effects Models for Planning and Management. The International Bank for Reconstruction and Development - The World Bank, Washington, Estados Unidos.
- Prasad, J. R., Kanuganti, S., Bhanegaonkar, P. N., Kumar-Sarkar, A., and Arkatkar, S. (2013). Development of relationship between roughness (iri) and visible surface distresses: A study on pmgsy roads. *Procedia - Social and Behavioral Sciences*, pages 322–331.
- Saghafi, B., Hassani, A., Noori, R., and Bustos, M. G. (2009). Artificial neural network and regression analysis for predicting faulting in jointed concrete pavements considering base condition. *International Journal of Pavement Research* and Technology, 2(1):20–25.
- Sayers, M. W., Gillespie, T. D., and Paterson, W. D. (1986a). Guidelines for Conducting and Calibrating Road Roughness Measurements. The International Bank for Reconstruction and Development - The World Bank, Washington, Estados Unidos.
- Sayers, M. W., Gillespie, T. D., and Queiroz, C. A. V. (1986b). The International Road Roughness Experiment-Establishing Correlation and a Calibration Standard for Measurements. The International Bank for Reconstruction and Development - The World Bank, Washington, Estados Unidos.
- Timm, D. H. and Turochy, R. E. (2014). Pavement condition model based on automated pavement distress surveys. Alabama Department of Transportation, pages 1–27.

- TNM (2013). Metodología general para la evaluación superficial, funcional y estructural del pavimento. Presentado al MTC como parte del Estudio Definitivo de Ingeniería.
- Varela, L. R. V. (2002). Pavement Condition Index (PCI) para Pavimentos Asfálticos y de Concreto en Carreteras. Ingepav, Manizales, Colombia.
- Vidya, R., Santhakumar, S. M., and Mathew, S. (2013). Estimation of iri from pci in construction work. ACEE Int. J. on Civil and Environmental Engineering, pages 1–5.





