

UNIVERSIDAD DE HUANUCO
FACULTAD DE INGENIERIA
PROGRAMA ACADÉMICO DE INGENIERIA CIVIL



TESIS

“Análisis de la variación del valor del índice de regularidad internacional (IRI) del pavimento flexible de 1 Km de longitud mediante redes neuronales y el perfilómetro láser, 2025”

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO CIVIL

AUTOR: Álvarez Robles, Franck Hussein

ASESORA: Arteaga Espinoza, Ingrid Delia Dignarda

HUÁNUCO – PERÚ

2026

U

D

H



UDH
UNIVERSIDAD DE HUANCAYO
<http://www.udh.edu.pe>

TIPO DEL TRABAJO DE INVESTIGACIÓN:

- Tesis ☒ (X)
- Trabajo de Suficiencia Profesional ☐ ()
- Trabajo de Investigación ☐ ()
- Trabajo Académico ☐ ()

LÍNEAS DE INVESTIGACIÓN: Transporte
AÑO DE LA LÍNEA DE INVESTIGACIÓN (2020)

CAMPO DE CONOCIMIENTO OCDE:

Área: Ingeniería y Tecnología

Sub área: Ingeniería Civil

Disciplina: Ingeniería del Transporte

DATOS DEL PROGRAMA:

Nombre del Grado/Título a recibir: Título

Profesional de Ingeniero Civil

Código del Programa: P07

Tipo de Financiamiento:

- Propio ☒ (X)
- UDH ☐ ()
- Fondos Concursables ☐ ()

DATOS DEL AUTOR:

Documento Nacional de Identidad (DNI): 76190139

DATOS DEL ASESOR:

Documento Nacional de Identidad (DNI): 73645168

Grado/Título: Magister en dirección de proyectos

Código ORCID: 0009-0001 0745-5433

DATOS DE LOS JURADOS:

Nº	APELLIDOS Y NOMBRES	GRADO	DNI	Código ORCID
1	García Echevarría, Ericka Selene	Magister en diseño y construcción de obras viales	23164212	0000-0002-6375-6855
2	Malpartida Valderrama, Yenerit Pamela	Magister en medio ambiente y desarrollo sostenible con mención en gestión ambiental	22516875	0000-0003-2705-4300
3	Zacarias Ventura, Héctor Raúl	Doctor en ciencias de la educación	22515329	0000-0002-7210-5675



UDH
UNIVERSIDAD DE HUÁNUCO
<http://www.udh.edu.pe>

UNIVERSIDAD DE HUÁNUCO

Facultad de Ingeniería

PROGRAMA ACADÉMICO DE INGENIERÍA CIVIL

ACTA DE SUSTENTACIÓN DE TESIS PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO(A) CIVIL

En la ciudad de Huánuco, siendo las 16:30 horas del día martes 22 de setiembre de 2026, en cumplimiento de lo señalado en el Reglamento de Grados y Títulos de la Universidad de Huánuco, se reunieron los Jurados Calificadores integrado por los docentes:

❖ MG. ERICKA SELENE GARCIA ECHEVARRIA	PRESIDENTE
❖ MG. YENERIT PAMELA MALPARTIDA VALDERRAMA	SECRETARIO
❖ DR. HECTOR RAUL ZACARIAS VENTURA	VOCAL

Nombrados mediante la RESOLUCIÓN No 1757-2026-D-FI-UDH, para evaluar la Tesis intitulada: "ANÁLISIS DE LA VARIACIÓN DEL VALOR DEL ÍNDICE DE REGULARIDAD INTERNACIONAL (IRI) DEL PAVIMENTO FLEXIBLE DE 1 KM DE LONGITUD MEDIANTE REDES NEURONALES Y EL PERFILÓMETRO LÁSER, 2025", presentado por el (la) Bachiller. Bach: Franck Hussein ALVAREZ ROBLES, para optar el Título Profesional de Ingeniero(a) Civil.

Dicho acto de sustentación se desarrolló en dos etapas: exposición y absolución de preguntas: procediéndose luego a la evaluación por parte de los miembros del Jurado.

Habiendo absuelto las objeciones que le fueron formuladas por los miembros del Jurado y de conformidad con las respectivas disposiciones reglamentarias, procedieron a deliberar y calificar, declarándolo(a) Aprobado por Unanimidad con el calificativo cuantitativo de 12 y cualitativo de suficiente (Art. 47).

Siendo las 17:20 horas del día 22 del mes de setiembre del año 2026, los miembros del Jurado Calificador firman la presente Acta en señal de conformidad.

MG. ERICKA SELENE GARCIA ECHEVARRIA

DNI: 23164212

ORCID: 0000-0002-6375-6855

PRESIDENTE

MG. YENERIT PAMELA MALPARTIDA VALDERRAMA

DNI: 22516875

ORCID: 0000-0003-2705-4300

SECRETARIO (A)

DR. HECTOR RAUL ZACARIAS VENTURA

DNI: 22515329

ORCID: 0000-0002-7210-5675

VOCAL



UNIVERSIDAD DE HUÁNUCO

CONSTANCIA DE ORIGINALIDAD

El comité de integridad científica, realizó la revisión del trabajo de investigación del estudiante: FRANCK HUSSEIN ALVAREZ ROBLES, de la investigación titulada "ANÁLISIS DE LA VARIACIÓN DEL VALOR DEL ÍNDICE DE REGULARIDAD INTERNACIONAL (IRI) DEL PAVIMENTO FLEXIBLE DE 1 KM DE LONGITUD MEDIANTE REDES NEURONALES Y EL PERFILÓMETRO LÁSER, 2025", con asesor(a) INGRID DELIA DIGNARDA ARTEAGA ESPINOZA, designado(a) mediante documento: RESOLUCIÓN N° 1845-2024-D-FI-UDH del P. A. de INGENIERÍA CIVIL.

Puede constar que la misma tiene un índice de similitud del 9 % verificable en el reporte final del análisis de originalidad mediante el Software Turnitin.

Por lo que concluyo que cada una de las coincidencias detectadas no constituyen plagio y cumple con todas las normas de la Universidad de Huánuco.

Se expide la presente, a solicitud del interesado para los fines que estime conveniente.

Huánuco, 12 de marzo de 2026



MANUEL E. ALIAGA VIDURIZAGA
D.N.I.: 71345687
cod. ORCID: 0009-0004-1375-5004

42. FRANCK HUSSEIN ALVAREZ ROBLES.docx

INFORME DE ORIGINALIDAD

9%

INDICE DE SIMILITUD

8%

FUENTES DE INTERNET

2%

PUBLICACIONES

5%

TRABAJOS DEL
ESTUDIANTE

FUENTES PRIMARIAS

1

repositorio.udh.edu.pe

Fuente de Internet

2%

2

hdl.handle.net

Fuente de Internet

1%

3

www.coursehero.com

Fuente de Internet

1%

4

Submitted to Universidad Politécnica del Perú

Trabajo del estudiante

1%

5

Submitted to Universidad Andina Nestor
Caceres Velasquez

Trabajo del estudiante

<1%



MANUEL E. ALIAGA VIDURIZAGA
D.N.I.: 71345687
cod. ORCID: 0009-0004-1375-5004

DEDICATORIA

A Dios, fuente de sabiduría y luz, por iluminar cada uno de mis días y fortalecer mi espíritu en los momentos de mayor desafío.

A mis padres, por su amor incondicional, sus sacrificios silenciosos y por confiar plenamente en mi capacidad para alcanzar mis objetivos. De ellos aprendí la perseverancia, la disciplina y el valor de la humildad como pilares fundamentales para superar cualquier obstáculo.

A mis docentes, quienes a lo largo de mi formación universitaria fueron verdaderos guías académicos. Con cada clase impartida, cada consejo y corrección, no solo me transmitieron conocimientos técnicos, sino que también despertaron en mí una profunda vocación por la Ingeniería Civil. Cada aprendizaje ha sido un peldaño en la edificación de mi desarrollo profesional y personal.

Y a mis amigos y compañeros de carrera, con quienes compartí innumerables jornadas de estudio, noches de desvelo y desafíos académicos. Su compañía convirtió este exigente recorrido en una experiencia significativa, enriquecedora e inolvidable.

AGRADECIMIENTO

Al culminar esta etapa crucial en mi formación profesional, deseo expresar mi más sincero agradecimiento a todas las personas que hicieron posible la realización y culminación de esta tesis, así como a quienes contribuyeron al desarrollo integral de mi carrera académica.

A Dios, por concederme la fortaleza diaria, la claridad mental y la luz necesaria para superar cada desafío a lo largo de este camino.

A los docentes que formaron parte de mi proceso de aprendizaje, por compartir generosamente sus conocimientos, experiencias y valores. Sus enseñanzas no solo enriquecieron mi formación técnica, sino que también fortalecieron mi compromiso ético y profesional.

A mi asesor de tesis, por su orientación metodológica y técnica, por su constante disposición y por los aportes sustanciales que permitieron enriquecer y consolidar este trabajo académico.

Y, finalmente, a todas las personas que, de manera directa o indirecta, contribuyeron con su apoyo, motivación o conocimiento a la concreción de este logro. Gracias por ser parte fundamental de este importante capítulo de mi vida.

ÍNDICE

DEDICATORIA	2
AGRADECIMIENTO	3
ÍNDICE	4
ÍNDICE DE TABLAS	7
ÍNDICE DE FIGURAS	8
RESUMEN	10
ABSTRACT	11
INTRODUCCIÓN	12
CAPÍTULO I	14
PROBLEMA DE INVESTIGACIÓN	14
1.1 DESCRIPCIÓN DEL PROBLEMA	14
1.2 FORMULACIÓN DEL PROBLEMA	15
1.2.1 PROBLEMA GENERAL	15
1.2.2 PROBLEMA ESPECÍFICO	15
1.3 OBJETIVO GENERAL	16
1.4 OBJETIVOS ESPECÍFICOS	16
1.5 JUSTIFICACIÓN DE LA INVESTIGACIÓN	16
1.5.1 JUSTIFICACIÓN TEÓRICA	16
1.5.2 JUSTIFICACIÓN PRÁCTICA	17
1.5.3 JUSTIFICACIÓN METODOLÓGICA	17
1.6 LIMITACIONES DE LA INVESTIGACIÓN	18
1.7 VIABILIDAD DE LA INVESTIGACIÓN	18
CAPÍTULO II	19
MARCO TEÓRICO	19
2.1 ANTECEDENTES DE LA INVESTIGACIÓN	19
2.1.1 ANTECEDENTES INTERNACIONALES	19
2.1.2 ANTECEDENTES NACIONALES	22
2.1.3 ANTECEDENTES LOCALES	25
2.2 BASES TEÓRICAS	25
2.2.1 CONCEPTOS BÁSICOS	25
2.2.2 COMPONENTES DEL PAVIMENTO	28
2.2.3 NORMATIVA Y ESTÁNDARES	33

2.2.4 REDES NEURONALES CONVOLUCIONALES (CNN)	34
2.2.5 PROCESAMIENTO DE IMÁGENES EN PAVIMENTOS.....	36
2.3 DEFINICIONES CONCEPTUALES.....	38
2.4 HIPÓTESIS	39
2.4.1 HIPÓTESIS GENERAL	39
2.5 VARIABLES	39
2.5.1 VARIABLE DE SUPERVISIÓN	39
2.5.2 VARIABLE ASOCIATIVA	40
2.6 OPERACIONALIZACIÓN DE VARIABLES (DIMENSIONES E INDICADORES)	41
CAPÍTULO III.....	42
METODOLOGÍA DE LA INVESTIGACIÓN	42
3.1 TIPO DE INVESTIGACIÓN	42
3.1.1 ENFOQUE	42
3.1.2 ALCANCE O NIVEL	42
3.1.3 DISEÑO	43
3.2 POBLACIÓN Y MUESTRA	44
3.2.1 POBLACIÓN	44
3.2.2 MUESTRA.....	44
3.3 TÉCNICAS E INSTRUMENTO DE RECOLECCIÓN DE DATOS.	44
3.3.1 PARA LA RECOLECCIÓN DE DATOS.....	44
3.3.2 TÉCNICAS	44
3.3.3 INSTRUMENTOS.....	45
3.3.4 PARA LA PRESENTACIÓN DE DATOS.....	47
3.3.5 PARA EL ANÁLISIS E INTERPRETACIÓN DE LOS DATOS	48
CAPÍTULO IV.....	49
RESULTADOS.....	49
4.1 PROCESAMIENTO DE DATOS.....	49
4.1.1 DATOS DEL PERFILÓMETRO LASER	49
4.1.2 MODELO DE ESTIMACIÓN IRI	53
4.1.3 INFORMACIÓN DE ENTRADA PARA EL MODELO NEURONAL	56
4.1.4 ARQUITECTURA DEL MODELO NEURONAL.....	58

4.1.5 MÉTODOS DE APRENDIZAJE DE RED NEURONAL	60
4.1.6 FUNCIÓN DE ACTIVACIÓN	63
4.2 CONTRASTACIÓN DE HIPÓTESIS Y PRUEBA DE HIPÓTESIS ...	73
CAPÍTULO V.....	75
DISCUSIÓN DE RESULTADOS.....	75
CONCLUSIONES	77
RECOMENDACIONES.....	78
REFERENCIAS BIBLIOGRÁFICAS.....	79
ANEXOS.....	82

ÍNDICE DE TABLAS

Tabla 1 Operacionalización de variables	41
Tabla 2 Modelo de los instrumentos que se van aplicar en la tesis	47
Tabla 3 Registro de perfilómetro láser – Margen Derecho	49
Tabla 4 Registro de perfilómetro laser – Margen Izquierdo	51
Tabla 5 Características a inventariar en el tramo.....	56
Tabla 6 Modelo de variables para la arquitectura del modelo.....	58
Tabla 7 Análisis de tendencias margen derecho	58
Tabla 8 Análisis de tendencias margen izquierdo.....	59
Tabla 9 Datos de entrada para la red neuronal.....	60
Tabla 10 Librerías aplicadas para la generación del modelo de red neuronal	62
Tabla 11 Matriz de Consistencia.....	85
Tabla 12 Análisis IRI margen derecho	88
Tabla 13 Análisis IRI margen Izquierdo	89
Tabla 14 Matriz PSI margen derecho	90
Tabla 15 Matriz PSI margen izquierdo.....	92
Tabla 16 Valores de variables ingresadas para entrenamiento – Carril derecho	94
Tabla 17 Valores de variables ingresadas para comprobación – Carril izquierdo	95
Tabla 18 Análisis de correlación carril derecho.....	101
Tabla 19 Análisis correlacional carril izquierdo	102

ÍNDICE DE FIGURAS

Figura 1 Capas que Componen un Pavimento Flexible	26
Figura 2 Diagrama del perfilómetro estático MERLIN	28
Figura 3 Suelos de subrasante	29
Figura 4 Estabilización de base y subbase	32
Figura 5 Perfilómetro laser (RSP) MK-IV	38
Figura 6 Ubicación del tramo analizado	49
Figura 7 Procesamiento de información	52
Figura 8 Estimación IRI entre progresivas 0+000 a 0+250	53
Figura 9 Estimación IRI entre progresivas 0+250 a 0+500	53
Figura 10 Estimación IRI entre progresivas 0+500 a 0+750	54
Figura 11 Estimación IRI entre progresivas 0+750 a 1+000	54
Figura 12 Estimación promedio de IRI a cada 20 m – Margen Derecho.....	55
Figura 13 Estimación promedio de IRI a cada 20 m – Margen Izquierdo	55
Figura 14 Características PSI carril derecho por progresiva.....	57
Figura 15 Características PSI carril izquierdo por progresiva	57
Figura 16 Esquema típico de red neuronal	60
Figura 17 Esquema de primer entrenamiento.....	63
Figura 18 Gráfica de erro cuadrático medio.....	64
Figura 19 Correlación de valores estimados y generados	64
Figura 20 Comparación con el carril izquierdo.....	65
Figura 21 Esquema del segundo entrenamiento	65
Figura 22 Gráfica de erro cuadrático medio.....	66
Figura 23 Correlación de valores estimados y generados	66
Figura 24 Comparación con el carril izquierdo.....	67
Figura 25 Esquema del tercer entrenamiento	67
Figura 26 Gráfica de erro cuadrático medio.....	68
Figura 27 Correlación de valores estimados y generados	68
Figura 28 Comparación con el carril izquierdo.....	69
Figura 29 Esquema del cuarto entrenamiento	69
Figura 30 Gráfica de erro cuadrático medio.....	70
Figura 31 Correlación de valores estimados y generados	70

Figura 32_Comparación con el carril izquierdo.....	71
Figura 33_Comparación de modelos de entrenamiento – Carril derecho.....	71
Figura 34_Comparación de modelos de verificación – Carril Izquierdo	72
Figura 35_Comparación de modelos de verificación – Carril Izquierdo	73
Figura 36_Ubicación de área de investigación	87
Figura 37_Código de programación de red neuronal.....	97

RESUMEN

Este estudio tiene como objetivo analizar la variación del Índice de Regularidad Internacional (IRI) en un tramo de 1 km de pavimento flexible en la Av. Universitaria de Huánuco, comparando los valores obtenidos mediante un modelo de Redes Neuronales Artificiales (RNA) y los valores reales medidos con el perfilómetro láser. El IRI es un indicador clave en la evaluación funcional de pavimentos, y su medición precisa permite tomar decisiones adecuadas para el mantenimiento vial. En contextos como el Perú, donde la tecnología aún no se aplica de forma homogénea, se busca explorar alternativas como las RNA para mejorar la predicción del deterioro vial.

El estudio emplea un enfoque cuantitativo, con un diseño no experimental, transversal, de tipo descriptivo y comparativo. Se recopiló datos de cinco variables agrupadas según la metodología PSI, utilizadas como entradas en diversos modelos de redes neuronales. El entrenamiento y validación de los modelos arrojaron resultados mixtos: se logró una alta correlación en la etapa de entrenamiento (superior a 0.93), pero un bajo ajuste en la validación (alrededor de 0.34), confirmando la hipótesis general de que existen diferencias significativas entre ambos métodos de evaluación.

Se concluye que las RNA pueden alcanzar buenos niveles de ajuste en entrenamiento si se definen correctamente las variables de entrada, la arquitectura de la red, el método de aprendizaje y la función de activación. Sin embargo, la validación con datos reales mostró que el modelo aún no generaliza adecuadamente, sugiriendo la necesidad de incorporar datos complementarios como imágenes o vibraciones. Este hallazgo es consistente con investigaciones similares, como la de Mayorga (2023), que destaca la importancia de una adecuada selección de datos y calibración del modelo.

Finalmente, se recomienda continuar el desarrollo de modelos híbridos que integren diferentes fuentes de información para mejorar la precisión en la predicción del IRI y contribuir a una gestión vial más eficiente y sostenible en zonas urbanas del Perú.

Palabras clave: Rugosidad, Redes Neuronales Artificiales (RNA/ANN), Perfilómetro Láser, Pavimento Flexible, Predicción.

ABSTRACT

This study aims to analyze the variation of the International Roughness Index (IRI) over a 1 km section of flexible pavement on Universitaria Avenue in Huánuco, comparing the values obtained through an Artificial Neural Network (ANN) model with actual values measured using a laser profilometer. The IRI is a key indicator in the functional evaluation of pavements, and accurate measurement enables appropriate decision-making for road maintenance. In contexts such as Peru, where technology is not yet applied uniformly, alternatives like ANNs are being explored to improve the prediction of road deterioration.

The study uses a quantitative approach, with a non-experimental, cross-sectional, descriptive, and comparative design. Data were collected from five variables grouped according to the PSI methodology, used as inputs for various neural network models. The training and validation of the models yielded mixed results: high correlation was achieved during the training phase (greater than 0.93), but the validation showed low fit (around 0.34), confirming the general hypothesis that significant differences exist between both evaluation methods.

It is concluded that ANNs can achieve good levels of fit during training if the input variables, network architecture, learning method, and activation function are properly defined. However, validation with real data showed that the model still does not generalize adequately, suggesting the need to incorporate complementary data such as images or vibrations. This finding is consistent with similar research, such as that by Mayorga (2023), which highlights the importance of appropriate data selection and model calibration.

Finally, it is recommended to continue developing hybrid models that integrate different sources of information to improve the accuracy of IRI prediction and contribute to more efficient and sustainable road management in urban areas of Peru.

Keywords: Roughness, Artificial Neural Networks (ANN), Laser Profilometer, Flexible Pavement, Prediction.

INTRODUCCIÓN

La gestión eficiente y sostenible de la infraestructura vial es un desafío fundamental en el desarrollo de los países, debido a la creciente demanda de transporte y la necesidad de garantizar condiciones óptimas de seguridad y confort para los usuarios. En este contexto, la evaluación del estado funcional de los pavimentos constituye un proceso clave para planificar el mantenimiento y prolongar la vida útil de las vías. El Índice de Regularidad Internacional (IRI) se ha consolidado como un estándar internacional para medir la calidad superficial del pavimento y su impacto en la experiencia de manejo, siendo ampliamente utilizado para determinar el confort y la seguridad vial, así como para estimar costos operativos vehiculares derivados del deterioro de la superficie.

En el ámbito tecnológico, el avance de herramientas como el perfilómetro láser ha permitido obtener mediciones precisas y rápidas del IRI, facilitando el monitoreo detallado del estado del pavimento. No obstante, en regiones con limitaciones en infraestructura y recursos, la implementación uniforme de estos dispositivos resulta todavía insuficiente, lo cual dificulta una gestión vial eficaz y oportuna. En paralelo, el uso de métodos computacionales avanzados, como las Redes Neuronales Artificiales, ha abierto nuevas posibilidades para el análisis y predicción de variables complejas mediante el procesamiento inteligente de grandes volúmenes de datos, presentando una alternativa prometedora para complementar las técnicas tradicionales de evaluación de pavimentos.

En el caso particular de la ciudad de Huánuco, la Av. Universitaria representa una vía estratégica para la conectividad urbana, la cual ha evidenciado un deterioro funcional considerable asociado al incremento del tránsito vehicular y las condiciones climáticas locales. Este deterioro se refleja en valores elevados del IRI, afectando no solo la comodidad y seguridad de los usuarios, sino también generando costos adicionales de operación vehicular y mantenimiento. Aunque la municipalidad ha implementado algunas intervenciones, estas han resultado insuficientes para garantizar un rendimiento adecuado del pavimento, lo que subraya la necesidad de adoptar enfoques más efectivos y tecnológicos para la evaluación y gestión vial.

Este estudio se propone analizar la variación del IRI del pavimento flexible en un tramo de 1 km de la Av. Universitaria mediante el uso combinado del perfilómetro láser y un modelo de Redes Neuronales Artificiales. La integración de ambas tecnologías permitirá obtener mediciones precisas y, al mismo tiempo, desarrollar un modelo predictivo que facilite la anticipación de deterioros futuros, optimizando así los programas de mantenimiento y contribuyendo a la sostenibilidad de la infraestructura vial en Huánuco. La presente investigación aporta un enfoque novedoso que podría replicarse en contextos similares, ampliando el uso de inteligencia artificial para la gestión vial en el Perú.

CAPÍTULO I

PROBLEMA DE INVESTIGACIÓN

1.1 DESCRIPCIÓN DEL PROBLEMA

La evaluación del estado funcional de los pavimentos flexibles es un aspecto crítico para la gestión vial en todo el mundo. A nivel internacional, el Índice de Regularidad Internacional (IRI) se ha establecido como un indicador clave para medir la calidad de rodadura y el confort de los usuarios. Según la Organización Mundial de Carreteras (PIARC, 2019), los altos valores de IRI indican condiciones de superficie deficientes que generan mayores costos operativos vehiculares, incrementan el desgaste de los pavimentos y afectan la seguridad vial. En países desarrollados, el uso de tecnologías avanzadas como el perfilómetro láser ha permitido una medición precisa del IRI, optimizando los programas de mantenimiento. Sin embargo, en regiones con infraestructura limitada, el monitoreo de este índice sigue siendo ineficiente, lo que afecta la planificación y sostenibilidad de las redes viales.

En el ámbito nacional, el Perú enfrenta grandes desafíos en la conservación de su infraestructura vial. Según el Instituto Nacional de Estadística e Informática (INEI, 2023), el 36% de las vías pavimentadas presentan un estado funcional entre regular y malo, lo que impacta negativamente en la competitividad del país y el desarrollo económico. Además, informes del Ministerio de Transportes y Comunicaciones (MTC, 2022) destacan que, aunque se ha incrementado el uso de tecnologías como el perfilómetro láser, estas herramientas aún no se emplean de manera uniforme en todas las regiones. Este hecho dificulta la implementación de estrategias efectivas para reducir los costos de mantenimiento y mejorar la durabilidad de los pavimentos. Paralelamente, la aplicación de redes neuronales para la predicción del IRI ha comenzado a desarrollarse como una alternativa eficiente para procesar grandes volúmenes de datos y generar modelos predictivos que optimicen las intervenciones viales. Sin embargo, su implementación aún es limitada debido a la falta de estudios específicos en diferentes contextos locales.

En el contexto local, específicamente en la ciudad de Huánuco, la Av. Universitaria constituye una vía de alto tránsito que conecta importantes

sectores comerciales y residenciales. Esta arteria, de aproximadamente 1 km de longitud, ha experimentado un deterioro significativo debido al incremento del tránsito vehicular pesado y a las condiciones climáticas de la región. El valor del IRI en esta vía es elevado, lo que evidencia un deterioro funcional que afecta la seguridad y comodidad de los usuarios, además de incrementar los costos de operación vehicular. Estudios preliminares realizados por la municipalidad indican que las intervenciones de mantenimiento han sido insuficientes para garantizar un desempeño óptimo del pavimento (Municipalidad Provincial de Huánuco, 2023).

La combinación del perfilómetro láser y redes neuronales ofrece una oportunidad para abordar esta problemática en la Av. Universitaria. El perfilómetro láser puede proporcionar mediciones precisas del IRI, mientras que las redes neuronales pueden analizar las variaciones temporales de este índice para predecir futuros deterioros y optimizar los programas de mantenimiento. No obstante, la falta de estudios locales que integren ambas tecnologías limita su aplicación efectiva. En este contexto, resulta crucial analizar la variación del valor del IRI en la Av. Universitaria utilizando estas herramientas para generar estrategias sostenibles y mejorar la calidad de la infraestructura vial en Huánuco.

1.2 FORMULACIÓN DEL PROBLEMA

1.2.1 Problema general

¿Cuál es el análisis de la variación del valor del Índice de Regularidad Internacional (IRI) del pavimento flexible de 1 km de longitud, al ser analizado mediante un modelo de Redes Neuronales Artificiales en comparación con el valor obtenido a través del Perfilómetro Láser?

1.2.2 Problema específico

¿Qué información será relevante y útil para incluir como entrada en el modelo neuronal, y cómo se puede asegurar su calidad y pertinencia?

¿Cómo se puede organizar la arquitectura del modelo neuronal para optimizar su desempeño y capacidad de aprendizaje en la tarea específica?

¿Cómo se establece la selección del método de aprendizaje más adecuado para el modelo neuronal, y cómo influirán en los resultados finales?

¿Cuál es la función de activación en el modelo neuronal para el diseño de un pavimento flexible?

1.3 OBJETIVO GENERAL

Analizar cómo varía el valor del Índice de Regularidad Internacional (IRI) del pavimento flexible de 1 km de longitud, a través de un modelo de Redes Neuronales Artificiales, en comparación con el valor obtenido utilizando el Perfilómetro Láser.

1.4 OBJETIVOS ESPECÍFICOS

Identificar qué información se utilizará como entrada en el modelo neuronal.

Definir cómo está organizada la arquitectura del modelo neuronal.

Establecer cuál será el método de aprendizaje más adecuado para el modelo neuronal, y cómo influirán en los resultados finales.

Identificar qué función de activación se implementará en el modelo neuronal.

1.5 JUSTIFICACIÓN DE LA INVESTIGACIÓN

1.5.1 Justificación teórica

La justificación teórica de esta investigación se fundamentará en la necesidad de aplicar técnicas avanzadas de análisis para evaluar la calidad del pavimento flexible, utilizando el Índice de Regularidad Internacional (IRI) como indicador clave. Se espera que, mediante el uso de Redes Neuronales Artificiales, se logre una estimación más precisa y eficiente del IRI en comparación con los métodos tradicionales, como el Perfilómetro Láser. Esto permitirá no solo identificar de manera más efectiva las variaciones en la calidad del pavimento, sino también optimizar el proceso de mantenimiento y rehabilitación de las vías en la localidad de Pillko Marca, Huánuco. La integración de estos enfoques teóricos y prácticos contribuirá a una comprensión más profunda de los factores que influyen en la degradación del pavimento, y se espera que los hallazgos de esta investigación sirvan como base para futuras aplicaciones y mejoras en la gestión de infraestructuras viales. Al

proporcionar un análisis más robusto y fundamentado, esta investigación promoverá el desarrollo de políticas y estrategias más efectivas en el mantenimiento de pavimentos, beneficiando a la comunidad local y al sistema de transporte regional en su conjunto.

1.5.2 Justificación práctica

La justificación práctica de esta tesis radicará en la necesidad de optimizar la evaluación de la calidad del pavimento en la Av. Universitaria de Pillko Marca, Huánuco. Se anticipa que el análisis de la variación del Índice de Regularidad Internacional (IRI) mediante la implementación de Redes Neuronales Artificiales y la comparación con los datos obtenidos del Perfilómetro Láser proporcionará información más precisa y accesible sobre el estado del pavimento. Esta metodología innovadora permitirá detectar de manera temprana deterioros y patologías en la infraestructura vial, facilitando la toma de decisiones informadas para el mantenimiento y rehabilitación de las carreteras. Asimismo, la utilización de tecnologías avanzadas contribuirá a la reducción de costos operativos y a la mejora de la seguridad vial, beneficiando a los usuarios y al desarrollo económico de la región. Además, el enfoque práctico de esta investigación servirá como referencia para futuras aplicaciones en otras áreas del país, promoviendo la adopción de metodologías modernas en la gestión de infraestructuras viales. En última instancia, se espera que los resultados de este estudio incidan positivamente en la planificación y ejecución de proyectos de infraestructura, mejorando así la calidad de vida de los habitantes de la localidad.

1.5.3 Justificación metodológica

La justificación metodológica para la tesis titulada "Análisis de la variación del valor del Índice de Regularidad Internacional (IRI) del pavimento flexible de 1 km de longitud mediante Redes Neuronales y el Perfilómetro Láser, Pillko Marca - Huánuco, 2025" se fundamentará en la necesidad de obtener un análisis preciso y confiable de la calidad del pavimento. Se aplicará un enfoque cuantitativo que combinará la recolección de datos a través del Perfilómetro Láser para obtener medidas objetivas del IRI y la implementación de un modelo de Redes Neuronales Artificiales, que permitirá predecir y analizar variaciones en

función de variables específicas. Este enfoque integrador se justificará al ofrecer no solo una comparación de resultados entre dos métodos, sino también la posibilidad de optimizar el proceso de evaluación del estado del pavimento, reduciendo costos y tiempos de análisis. Además, se espera que los resultados de este estudio contribuyan a la toma de decisiones informadas para el mantenimiento y rehabilitación de infraestructuras viales, alineándose con las tendencias modernas en el uso de tecnología para la gestión de carreteras. En consecuencia, la metodología propuesta se considerará un aporte significativo al conocimiento y práctica en el ámbito de la ingeniería civil y la gestión de pavimentos.

1.6 LIMITACIONES DE LA INVESTIGACIÓN

Las limitaciones de la investigación se centrarán en la disponibilidad de datos, ya que la calidad y cantidad de la información recolectada influirán directamente en la precisión del modelo neuronal. Además, se podrían presentar restricciones relacionadas con el tiempo y recursos disponibles para realizar las evaluaciones de campo, así como la variabilidad en las condiciones climáticas durante la recolección de datos, que afectarán la repetibilidad de los resultados.

1.7 VIABILIDAD DE LA INVESTIGACIÓN

La viabilidad de la investigación se asegurará a través del acceso a tecnología adecuada, como el Perfilómetro Láser y software para el desarrollo de modelos de Redes Neuronales. Además, la disponibilidad de datos históricos y la colaboración con instituciones locales permitirán un análisis exhaustivo. Se prevé que los resultados generen un impacto positivo en la gestión de pavimentos, facilitando la toma de decisiones informadas para el mantenimiento de infraestructuras viales.

CAPÍTULO II

MARCO TEÓRICO

2.1 ANTECEDENTES DE LA INVESTIGACIÓN

2.1.1 Antecedentes Internacionales

Malo (2024) En su trabajo de investigación titulado: *“Estudio comparativo de estructuras de pavimento convencional, pavimento sobre suelo estabilizado con cemento y pavimento reforzado con Geosintéticos, del caso de estudio Vía Zhidmad-Jadan”*, realizado en la Universidad Politécnica Salesiana, en Cuenca - Ecuador. El objetivo principal del estudio fue comparar el desempeño y la eficacia de tres tipos de estructuras de pavimento en la Vía Zhidmad-Jadan: pavimento convencional, pavimento sobre suelo estabilizado con cemento y pavimento reforzado con geosintéticos, con el fin de determinar la mejor alternativa en términos de durabilidad, costo y facilidad de construcción. La metodología empleada incluyó una revisión bibliográfica exhaustiva sobre cada tipo de pavimento, seguida de análisis de laboratorio y ensayos in situ para evaluar las propiedades mecánicas del suelo y de las capas de pavimento. También se realizaron simulaciones numéricas y se aplicaron criterios de diseño estándar para evaluar la capacidad estructural de cada alternativa. Los resultados mostraron que el pavimento reforzado con geosintéticos presentó un mejor rendimiento en cuanto a resistencia a la deformación y durabilidad a largo plazo, mientras que el pavimento sobre suelo estabilizado con cemento ofreció una solución económica y eficaz en condiciones de tráfico moderado. Las conclusiones del estudio resaltan la importancia de seleccionar la estructura de pavimento más adecuada en función de las condiciones específicas del proyecto, y sugieren que el uso de geosintéticos podría ser una alternativa viable y sostenible en proyectos similares, especialmente en zonas con suelos problemáticos.

Cevallos (2023) En su trabajo de investigación titulado: *“Elaboración de un proceso de conservación de la estructura del pavimento de la vía camino real (norte) en el tramo km 3+800 hasta km 7+600 del cantón Ambato, provincia de Tungurahua”*, realizado en la

Universidad Técnica De Ambato, en Ambato - Ecuador. El objetivo principal del estudio fue desarrollar un proceso efectivo para la conservación de la estructura del pavimento en un tramo específico de la vía Camino Real, con el fin de prolongar su vida útil y mejorar la seguridad vial. La metodología del estudio incluyó un diagnóstico inicial del estado del pavimento mediante inspecciones visuales y pruebas técnicas, como la evaluación de la rugosidad y la resistencia estructural. A partir de los datos recopilados, se diseñó un plan de conservación que abarcaba desde el sellado de grietas hasta la rehabilitación de capas superficiales, utilizando técnicas y materiales adecuados para las condiciones locales. Los resultados del estudio mostraron que la implementación del proceso propuesto podría reducir significativamente el deterioro del pavimento y los costos de mantenimiento a largo plazo. Las conclusiones destacaron la importancia de un mantenimiento preventivo y planificado, subrayando que un enfoque proactivo en la conservación del pavimento es esencial para asegurar la funcionalidad y seguridad de las vías, especialmente en regiones con alto tránsito y condiciones climáticas variables.

Mayorga (2023) en su trabajo de investigación intitulado: *“Diseño de un modelo de aprendizaje de máquina para reconocimiento y clasificación de daños en pavimento para vías de Sogamoso.”* la metodología consistió en el desarrollo de un modelo de aprendizaje de máquina basado en imágenes y datos de sensores para reconocer y clasificar distintos tipos de daños en pavimentos. El estudio incluyó la recopilación de imágenes de vías en la ciudad de Sogamoso mediante la aplicación de cámaras instaladas en vehículos, junto con datos adicionales de vibración obtenidos a través de sensores como acelerómetros. Estos datos fueron procesados y etiquetados para entrenar el modelo utilizando algoritmos de aprendizaje automático, entre los que se destacaron las redes neuronales convolucionales (CNN) para el análisis de imágenes. Se llevaron a cabo pruebas de validación con un conjunto de datos de prueba, evaluando el rendimiento del modelo en términos de precisión, sensibilidad y especificidad. En cuanto a los resultados, el modelo alcanzó una precisión del 92% en la

clasificación de daños, identificando correctamente grietas, baches y deformaciones en el pavimento. La sensibilidad del modelo fue del 90%, mientras que la especificidad fue del 88%, lo que refleja una alta capacidad para diferenciar entre daños reales y otras irregularidades en la superficie. El tiempo promedio de procesamiento de cada imagen fue de 1.8 segundos, lo que demuestra una eficiencia adecuada para el análisis en tiempo real. Además, se determinó que la aplicación combinada de imágenes y datos de sensores mejoró en un 12% la precisión del modelo en comparación con el empleo exclusivo de imágenes. Las conclusiones destacaron que el modelo propuesto es una herramienta efectiva para la gestión del mantenimiento vial, permite identificar y clasificar de manera automática los daños en pavimentos, lo cual optimiza los recursos destinados a la reparación y mejora la seguridad vial. Se concluyó que la implementación de este sistema en las vías de Sogamoso ayudaría a reducir los costos operacionales de inspección y monitoreo, al tiempo que proporcionaría información precisa y en tiempo real sobre el estado de las carreteras, facilitando la toma de decisiones en cuanto a planes de mantenimiento.

Duarte y Cabrera (2022) En su trabajo de investigación titulado: *“Diseño de 1,500.00 metros de pavimento articulado por método AASHTO 93 y drenaje menor en el barrio San José, Santo Tomas, Chontales”*, realizado en la Universidad Nacional de Ingeniería, en Managua - Nicaragua. El principal objetivo del estudio fue diseñar un pavimento articulado para una longitud de 1,500 metros en el barrio San José, utilizando el método AASHTO 93, y abordar el diseño de drenaje menor necesario para asegurar la durabilidad y funcionalidad del pavimento en condiciones locales. La metodología del estudio incluyó un análisis detallado de las condiciones del suelo, evaluaciones del tránsito previsto, y la aplicación del método AASHTO 93 para determinar los espesores adecuados de las capas del pavimento. Además, se realizaron cálculos hidráulicos para diseñar el sistema de drenaje menor, considerando las precipitaciones y características topográficas de la zona. Los resultados indicaron que el diseño propuesto cumple con los estándares de durabilidad y capacidad estructural requeridos para

soportar el tráfico estimado en la zona, y que el sistema de drenaje diseñado es adecuado para manejar las aguas pluviales sin comprometer la integridad del pavimento. Las conclusiones subrayan la importancia de seguir un enfoque riguroso en el diseño de pavimentos y sistemas de drenaje, especialmente en áreas con condiciones climáticas variables, para garantizar la sostenibilidad y la funcionalidad a largo plazo de las infraestructuras viales.

2.1.2 Antecedentes Nacionales

Chino y Inchicsana (2024) en su trabajo de investigación intitulado: *“Aplicación de Deep Learning para la detección de anomalías en pavimento en una zona del distrito de “Socabaya”, Arequipa 2024.”* la metodología empleada se centró en el empleo de algoritmos de Deep Learning para la identificación automática de anomalías en pavimentos. Para ello, se recolectaron imágenes de la superficie del pavimento de una zona específica del distrito de Socabaya mediante cámaras instaladas en vehículos, las cuales fueron procesadas y etiquetadas según el tipo de anomalía presente, como grietas, baches o deformaciones. El modelo fue entrenado utilizando redes neuronales convolucionales (CNN), que fueron seleccionadas por su capacidad para el análisis y clasificación de imágenes. Se utilizó un conjunto de datos balanceado para mejorar la precisión del modelo, y se llevaron a cabo pruebas de validación utilizando métricas como la precisión, sensibilidad y especificidad para evaluar su desempeño. En cuanto a los resultados, el modelo alcanzó una precisión del 94% en la detección de anomalías, superando a otros enfoques tradicionales de análisis de imágenes. La sensibilidad fue del 92%, lo que refleja una alta capacidad para detectar daños en las condiciones de prueba, mientras que la especificidad se situó en un 89%, indicando una baja tasa de falsos positivos. El tiempo promedio de procesamiento de cada imagen fue de 1.6 segundos, lo que demostró la viabilidad del sistema para su empleo en tiempo real en vehículos en movimiento. Además, se determinó que el empleo de técnicas de aumento de datos mejoró en un 10% la precisión del modelo. En las conclusiones, los autores indicaron que la aplicación de Deep Learning es una herramienta altamente efectiva para la detección

automática de anomalías en pavimentos, lo cual representa un avance significativo en la gestión del mantenimiento vial. Se concluyó que la implementación de este sistema en el distrito de Socabaya permitiría optimizar los recursos destinados a la reparación de vías, reducir los costos de inspección manual y aumentar la eficiencia en la identificación de daños. Asimismo, se destacó que este tipo de tecnología se integra en sistemas más amplios de monitoreo de infraestructuras urbanas, mejorando la seguridad vial y la durabilidad de los pavimentos.

Chugnas y Flores (2021) En su trabajo de investigación titulado: *“Diseño de pavimento flexible de la carretera Cosma tramo Km 05+213 – Km 10+213 empleando el Método AASHTO-93 Cáceres del Perú, Jimbe - 2021”*, realizado en la Universidad César Vallejo, en Chimbote - Perú. El objetivo principal del estudio fue diseñar un pavimento flexible para un tramo de 5 kilómetros de la carretera Cosma, utilizando el Método AASHTO-93, con el fin de mejorar la transitabilidad y las condiciones de seguridad de la vía en la zona de Jimbe. La metodología empleada en el estudio incluyó un análisis exhaustivo de las características del tráfico, las condiciones climáticas y las propiedades del suelo en el área de estudio. Se realizaron ensayos de laboratorio para determinar las propiedades mecánicas del suelo y los materiales de pavimentación, así como simulaciones utilizando el método AASHTO-93 para definir los espesores óptimos de las capas del pavimento. Los resultados del estudio indicaron que el diseño propuesto cumple con los estándares de capacidad estructural y durabilidad requeridos para soportar las cargas vehiculares previstas, asegurando una vida útil adecuada del pavimento. Las conclusiones del estudio subrayaron la importancia de seguir criterios de diseño específicos y adaptados a las condiciones locales para garantizar la eficiencia y sostenibilidad de las infraestructuras viales, destacando que el Método AASHTO-93 es una herramienta efectiva para el diseño de pavimentos flexibles en regiones con características similares a las de la zona de estudio.

Contreras (2022) En su trabajo de investigación titulado: *“Diseño de pavimento flexible con tratamiento superficial bicapa del camino vecinal intersección de vía a Huancavelica – Occoropuquio”*, realizado

en la Universidad Peruana los Andes, en Huancayo - Perú. El objetivo principal del estudio fue diseñar un pavimento flexible con un tratamiento superficial bicapa para un camino vecinal que conecta la intersección de la vía a Huancavelica con Occoropuquio, con el propósito de mejorar la transitabilidad y prolongar la vida útil de la vía en condiciones locales. La metodología del estudio incluyó un análisis detallado de las condiciones existentes del camino, incluyendo la evaluación del tránsito vehicular, las características geotécnicas del suelo y las condiciones climáticas de la región. Se realizaron ensayos de laboratorio para determinar las propiedades de los materiales de construcción y se aplicaron principios de diseño de pavimentos flexibles, junto con la selección y diseño del tratamiento superficial bicapa, para asegurar una superficie de rodadura resistente y duradera. Los resultados del estudio mostraron que el diseño propuesto es adecuado para las condiciones de carga y ambientales de la zona, proporcionando una solución efectiva y de bajo costo para el mejoramiento del camino vecinal. Las conclusiones subrayaron que el uso del tratamiento superficial bicapa, combinado con un diseño de pavimento flexible bien fundamentado, puede ofrecer una alternativa viable para la rehabilitación y mantenimiento de caminos rurales en regiones similares, mejorando significativamente la calidad de vida de las comunidades locales mediante la mejora de su conectividad vial.

González y Rodas (2022) En su trabajo de investigación titulado: *“Diseño de pavimento flexible usando la metodología AASHTO-93 para las avenidas Aviación y Víctor Raúl Huanchaquito - Huanchaco Trujillo - La Libertad 2022”*, realizado en la Universidad César Vallejo, en Perú. El objetivo principal del estudio fue diseñar un pavimento flexible para las avenidas Aviación y Víctor Raúl en la zona de Huanchaquito, utilizando la metodología AASHTO-93, con el fin de mejorar la infraestructura vial y garantizar una mayor durabilidad frente al tráfico y las condiciones ambientales locales. La metodología del estudio involucró la recopilación de datos de tráfico, el análisis de las propiedades del suelo y la determinación de las cargas de diseño, seguido por el uso de la metodología AASHTO-93 para calcular los espesores adecuados de las capas del pavimento. Se realizaron pruebas de laboratorio para

caracterizar los materiales y asegurar que cumplan con los estándares necesarios para el diseño. Los resultados indicaron que el pavimento diseñado conforme a la metodología AASHTO-93 proporciona la resistencia estructural requerida para soportar el tráfico proyectado en las avenidas, asegurando una vida útil prolongada y un mantenimiento eficiente. Las conclusiones del estudio destacaron la efectividad de la metodología AASHTO-93 en el diseño de pavimentos flexibles para vías urbanas, subrayando que su aplicación adecuada puede contribuir significativamente a la mejora de la calidad y sostenibilidad de la infraestructura vial en regiones como Trujillo, donde las condiciones de tráfico y ambientales son exigentes.

2.1.3 Antecedentes Locales

No existe ningún antecedente local hasta el momento.

2.2 BASES TEÓRICAS

2.2.1 Conceptos Básicos

2.2.1.1 Pavimentos flexibles

El pavimento flexible es un tipo de estructura vial que se caracteriza por su capacidad de distribuir las cargas aplicadas por el tráfico sobre una base más elástica, permitiendo que la deformación se propague a través de las capas de la estructura. Este tipo de pavimento está compuesto por varias capas, siendo la superior una capa de rodadura, generalmente constituida por mezcla asfáltica, que proporciona una superficie de alta resistencia al desgaste y la abrasión. Debajo de esta capa se encuentra una base granular, que sirve para distribuir las cargas de tráfico, y una subbase que proporciona soporte adicional y ayuda en la absorción de las cargas aplicadas (Chavez, 2019).

Una de las principales ventajas del pavimento flexible es su capacidad de adaptarse a las condiciones del terreno y sus menores costos iniciales en comparación con los pavimentos rígidos. Sin embargo, su desempeño a largo plazo depende de una correcta construcción y mantenimiento, ya que está más expuesto al deterioro debido a factores como el tránsito pesado, las condiciones climáticas extremas y la calidad de los materiales

utilizados en su fabricación. Las técnicas de diseño y análisis de pavimentos flexibles, como el Método AASHTO 93, permiten calcular las capas adecuadas y los espesores necesarios para garantizar una vida útil prolongada y un buen desempeño (Chavez, 2019).

En el contexto peruano, el pavimento flexible se utiliza ampliamente debido a su versatilidad y el menor costo comparado con los pavimentos rígidos. Sin embargo, el mantenimiento de pavimentos flexibles en áreas urbanas y rurales presenta desafíos significativos debido a la creciente carga vehicular y las condiciones climáticas adversas. Es importante realizar evaluaciones periódicas del estado del pavimento, utilizando métodos como el Índice de Regularidad Internacional (IRI), para planificar intervenciones eficaces que aseguren la durabilidad de la infraestructura vial (Chavez, 2019).

Figura 1

Capas que Componen un Pavimento Flexible



Fuente. (Martínez, 2024)

2.2.1.2 Índice de Regularidad Internacional (IRI)

El Índice de Regularidad Internacional (IRI) es una métrica estándar utilizada globalmente para evaluar la regularidad superficial de pavimentos. Este índice mide las irregularidades longitudinales que afectan la comodidad de los usuarios y el desempeño del vehículo. El IRI se expresa en metros por kilómetro (m/km), donde un valor más bajo indica una superficie más regular. Esta métrica es crucial en el diseño, mantenimiento y rehabilitación


de pavimentos, dado que un IRI elevado puede implicar costos adicionales de operación vehicular y menores niveles de servicio (Arteaga y Noriega, 2019).

En el contexto peruano, se han realizado diversas investigaciones sobre la aplicación del IRI, considerando tanto tecnologías tradicionales como modernas. Por ejemplo, en un estudio en la Universidad Ricardo Palma, se compararon resultados obtenidos mediante el uso del dispositivo MERLIN y un perfilómetro láser en vías rurales. Este análisis demostró que las irregularidades más notorias suelen presentarse en tramos con geometrías complejas, como curvas consecutivas, lo que subraya la importancia de la evaluación constante de la regularidad para planificar intervenciones adecuadas en infraestructura vial. Además, el uso de tecnologías avanzadas como el perfilómetro láser y métodos alternativos, incluidos sensores inerciales y aplicativos móviles, ha optimizado la precisión y la cobertura en la medición del IRI en el país (MTC, 2020).

El IRI no solo es un indicador técnico, sino también un parámetro esencial para evaluar el impacto económico y social de las condiciones viales. Su correcta implementación permite no solo priorizar inversiones en conservación vial, sino también mejorar la seguridad y reducir los costos operativos, contribuyendo al desarrollo sostenible de la infraestructura vial del Perú (MTC, 2020).

Figura 2

Diagrama del perfilómetro estático MERLIN



Fuente. (Servando y Rafael, 2012)

2.2.2 Componentes del Pavimento


2.2.2.1 Subrasante

a) Definición y Función Principal

La subrasante es la capa inferior del sistema de pavimento y constituye el soporte fundamental sobre el cual se construyen todas las capas superiores del pavimento. La subrasante se refiere al suelo natural compactado y preparado que sirve de base para la estructura del pavimento. Su función principal es distribuir las cargas aplicadas por el tráfico vehicular hacia las capas inferiores del suelo, evitando deformaciones y fallas estructurales en el pavimento (MTC, 2014).

Figura 3

Suelos de subrasante



Fuente. (MTC, 2014)

b) Evaluación de la Subrasante

La calidad y características de la subrasante son cruciales para el desempeño a largo plazo del pavimento. En Perú, se lleva a cabo una evaluación detallada de la subrasante, que incluye pruebas de resistencia y capacidad de soporte, como el Índice de California Bearing Ratio (CBR), que mide la capacidad de soporte del suelo en comparación con un material estándar. Además, la compactación de la subrasante debe cumplir con especificaciones técnicas precisas para asegurar que tenga la densidad y estabilidad adecuadas (MTC, 2014).

c) Consideraciones Ambientales y Geotécnicas

El diseño de la subrasante también debe considerar factores ambientales y geotécnicos específicos de la región, como la presencia de suelos expansivos, condiciones de humedad, y la posible incidencia de fenómenos naturales como lluvias intensas o sismos. La normativa de construcción vial establece directrices para la preparación y mejoramiento de la subrasante, incluyendo

métodos para estabilizar suelos problemáticos mediante el uso de aditivos como cal o cemento (MTC, 2014).

d) Importancia en la Durabilidad del Pavimento

La importancia de una subrasante bien diseñada y construida radica en su influencia directa en la durabilidad y el desempeño del pavimento. Una subrasante inadecuada puede resultar en asentamientos, agrietamientos y otras fallas que afectan la funcionalidad y seguridad de la vía (MTC, 2014).

2.2.2.2 Subbase

La subbase es una capa fundamental en la estructura del pavimento, ubicada entre la subrasante y la base del pavimento. Su principal función es proporcionar soporte estructural adicional, distribuir las cargas del tráfico de manera uniforme y mejorar la capacidad de drenaje del sistema de pavimento. En el contexto peruano, la subbase se construye generalmente con materiales granulados seleccionados y compactados, que deben cumplir con especificaciones técnicas rigurosas para asegurar su desempeño adecuado (MTC, 2014).

La subbase ayuda a prevenir la acumulación de agua en la subrasante, lo cual es crucial para mantener la estabilidad del pavimento, especialmente en zonas con altas precipitaciones o suelos con pobre capacidad de drenaje. Además, la subbase actúa como una capa de transición que reduce los efectos de las cargas dinámicas sobre la subrasante, mejorando la durabilidad del pavimento (MTC, 2014).

2.2.2.3 Base

La base es una de las capas más críticas en la estructura del pavimento, ubicada directamente debajo de la capa de rodadura y sobre la subbase. Su función principal es proporcionar una plataforma sólida y estable para la capa de rodadura, distribuyendo las cargas del tráfico hacia las capas inferiores de manera eficiente. La base se construye utilizando materiales de alta calidad, como agregados triturados, grava o mezclas estabilizadas, que deben

cumplir con especificaciones técnicas detalladas para garantizar su rendimiento óptimo (CPA, 2016).

e) Características y Requisitos de los Materiales

La capa base tiene que tener una alta capacidad de soporte y resistencia a la deformación para soportar las cargas dinámicas y estáticas del tráfico vehicular. Las normativas del Ministerio de Transportes y Comunicaciones establecen los criterios específicos para los materiales utilizados en la construcción de la base, que incluyen propiedades físicas como granulometría, densidad, resistencia a la compresión y durabilidad. (CPA, 2016).

f) Compactación y Colocación de la Capa Base


La adecuada compactación y colocación de la capa base es fundamental para el éxito del pavimento. La compactación debe ser uniforme y alcanzar la densidad especificada para evitar problemas futuros como asentamientos diferenciales y deformaciones. El proceso de construcción de la base también debe incluir un control de calidad riguroso para verificar que los materiales cumplan con las especificaciones y que la compactación sea adecuada (CPA, 2016).

g) Función en el Drenaje del Pavimento

Además de su función estructural, la base también puede desempeñar un papel importante en el drenaje del pavimento, ayudando a prevenir la acumulación de agua en las capas superiores y la subrasante, lo cual es crucial para mantener la integridad del pavimento en condiciones climáticas adversas (CPA, 2016).

Figura 4

Estabilización de base y subbase



Fuente. (CPA, 2016).

2.2.2.4 Capas de Rodadura

La capa de rodadura es la capa superior del pavimento y su función principal es proporcionar una superficie de rodadura segura y duradera para los vehículos. Esta capa está expuesta directamente al tráfico vehicular y a las condiciones climáticas, por lo que debe ser capaz de resistir el desgaste y las condiciones adversas sin comprometer la seguridad ni el confort de los usuarios (León y Gil, 2019).

h) Materiales Utilizados en Perú

La capa de rodadura se construye utilizando mezclas asfálticas o de concreto, dependiendo de las especificaciones del proyecto y las condiciones del lugar. Las mezclas asfálticas pueden incluir diferentes tipos de agregados y asfaltos modificados para mejorar la resistencia al desgaste, la adherencia y la impermeabilidad. Por otro lado, las capas de rodadura de concreto se utilizan en áreas donde se requiere una mayor resistencia

estructural y durabilidad, como en zonas de alto tráfico o condiciones climáticas extremas (León y Gil, 2019).

i) Consideraciones de Diseño

El diseño de la capa de rodadura debe considerar factores como el tipo y volumen de tráfico, las condiciones climáticas y las características del suelo. En Perú, el Ministerio de Transportes y Comunicaciones proporciona directrices y especificaciones para el diseño y construcción de las capas de rodadura, asegurando que cumplan con los requisitos de calidad y rendimiento necesarios (León y Gil, 2019).

j) Control de Calidad en la Construcción

Además, la capa de rodadura debe ser construida con un control de calidad riguroso, que incluye la verificación de la composición de la mezcla, el proceso de colocación y el curado. Una adecuada capa de rodadura no solo mejora la durabilidad del pavimento, sino que también contribuye a la seguridad y comodidad del tránsito vehicular (León y Gil, 2019).

2.2.3 Normativa y Estándares

2.2.3.1 Normativa Nacional e Internacional

La normativa nacional e internacional establece los requisitos y directrices para el diseño, construcción y mantenimiento de pavimentos. En el ámbito nacional, en Perú, las normativas proporcionadas por el Ministerio de Transportes y Comunicaciones (MTC) son fundamentales. Estas directrices incluyen especificaciones técnicas para la selección de materiales, procedimientos de construcción y control de calidad. Entre las normas nacionales se destacan el "Manual de Carreteras: Diseño Geométrico DG-2018" y el "Manual de Seguridad Vial RD N° 05-2017-MTC/14", que proporcionan criterios específicos para el diseño y la seguridad vial (MTC, 2014).

A nivel internacional, se utilizan estándares como los de la Asociación Americana de Oficiales de Carreteras Estatales y Transportes (AASHTO) y la Organización Internacional para la Normalización (ISO). La normativa AASHTO, especialmente el

Método AASHTO93, es ampliamente adoptada en diversos países para el diseño de pavimentos, mientras que la ISO proporciona estándares globales que abarcan desde la calidad de los materiales hasta los procedimientos de prueba y control (MTC, 2014).

2.2.3.2 Especificaciones Técnicas

Las especificaciones técnicas son documentos detallados que establecen los requisitos específicos para los materiales, métodos de construcción y criterios de calidad en el diseño y ejecución de pavimentos. Estas especificaciones incluyen parámetros como la granulometría de los agregados, la resistencia del concreto o asfalto, y las técnicas de compactación y colocación (MTC, 2018).

Las especificaciones técnicas se encuentran en los manuales del Ministerio de Transportes y Comunicaciones, como el "Manual de Carreteras: Diseño Geométrico DG-2018". Estas especificaciones aseguran que los proyectos de pavimentación cumplan con los estándares necesarios para garantizar la durabilidad y el desempeño adecuado del pavimento. También se incluyen criterios para la inspección y el control de calidad durante las fases de construcción y mantenimiento (MTC, 2018).

A nivel internacional, las especificaciones técnicas se alinean con las normas establecidas por organizaciones como la AASHTO y la ISO, que proporcionan directrices para asegurar la calidad y el desempeño del pavimento en diferentes contextos climáticos y geotécnicos (MTC, 2018).

2.2.4 Redes Neuronales Convolucionales (CNN)

2.2.4.1 Estructura y funcionamiento de las CNN

Las Redes Neuronales Convolucionales (CNN) son una clase de redes neuronales profundas que se utilizan predominantemente en el análisis de imágenes. Se caracterizan por su capacidad para extraer automáticamente características jerárquicas de los datos de entrada a través de una serie de capas convolucionales y de agrupamiento, lo que permite el reconocimiento y clasificación de patrones visuales con alta precisión (Rajalingappaa, 2019).

Las CNN son modelos de aprendizaje profundo diseñados para procesar datos que tienen una estructura de cuadrícula, como las imágenes. Su arquitectura se basa en la aplicación de filtros convolucionales que detectan patrones locales, seguido de una combinación de estas características a través de capas totalmente conectadas. Esto les permite lograr un rendimiento superior en tareas de reconocimiento visual, superando a los métodos tradicionales (Fernández y López, 2021).

Las Redes Neuronales Convolucionales son una variante de las redes neuronales que se especializan en el procesamiento de datos visuales. Utilizan operaciones de convolución para extraer características relevantes de las imágenes, lo que las hace eficientes en la clasificación y detección de objetos. Su diseño incluye capas convolucionales, de activación y de agrupamiento, que permiten un aprendizaje efectivo y una reducción de la dimensionalidad de los datos (García, 2018).

2.2.4.2 Ventajas de las CNN en la detección de anomalías

Las Redes Neuronales Convolucionales (CNN) son especialmente eficaces en la detección de anomalías debido a su capacidad para aprender representaciones jerárquicas de características en imágenes. Su estructura convolucional permite identificar patrones complejos y sutiles, lo que las convierte en una herramienta poderosa para reconocer comportamientos atípicos en conjuntos de datos visuales (Rosebrock, 2017).

Las CNN ofrecen ventajas significativas en la detección de anomalías en datos de series temporales, gracias a su habilidad para captar relaciones espaciales y temporales. Esta capacidad les permite identificar desviaciones de patrones normales con alta precisión, lo que es crucial para aplicaciones en vigilancia y monitoreo de sistemas críticos (Patel, 2021).

Las Redes Neuronales Convolucionales son particularmente útiles en la detección de anomalías porque manejan datos no estructurados y extraer características relevantes sin necesidad de ingeniería de características manual. Esto reduce el tiempo de

desarrollo y mejora la capacidad de generalización del modelo, facilitando la identificación de anomalías en contextos variados, desde la medicina hasta la seguridad informática (Torres, 2022).

2.2.5 Procesamiento de Imágenes en Pavimentos

2.2.5.1 Tipos de imágenes utilizadas en la evaluación de pavimentos

El procesamiento de imágenes en la evaluación de pavimentos es un conjunto de técnicas computacionales que permiten la adquisición, análisis y mejora de imágenes de superficies de pavimento. Estas técnicas son fundamentales para identificar deterioros, clasificar el estado del pavimento y facilitar la toma de decisiones en el mantenimiento y la gestión de infraestructuras viales (Kumar, 2021).

El procesamiento de imágenes en la evaluación de pavimentos involucra la aplicación de herramientas de visión por computadora para extraer información útil de las imágenes capturadas. Esta información se utiliza para detectar fallas, medir la textura y evaluar la condición de los pavimentos, mejorando así la eficiencia de las inspecciones viales y la planificación del mantenimiento (Li, 2019).

El procesamiento de imágenes como una metodología que utiliza imágenes digitales para analizar las características de los pavimentos. Este enfoque permite la identificación automática de daños como grietas, deformaciones y desgaste, facilitando una evaluación más precisa del estado estructural del pavimento y optimizando los recursos para su reparación y mantenimiento (Torres, 2020).

2.2.5.2 Técnicas de preprocesamiento de imágenes

El preprocesamiento de imágenes es un conjunto de técnicas destinadas a mejorar la calidad de las imágenes adquiridas de los pavimentos. Este proceso incluye la eliminación de ruidos, el ajuste del contraste y la normalización, permitiendo así una mejor visualización y análisis de los defectos del pavimento, lo cual es esencial para un diagnóstico preciso (Ramírez, 2022).

Las técnicas de preprocesamiento de imágenes son fundamentales para preparar los datos visuales antes de su análisis. Esto implica aplicar filtros y transformaciones que realzan las características relevantes de las superficies pavimentadas, facilitando así la detección de deterioros y la planificación de mantenimientos adecuados (Martínez, 2023).

El preprocesamiento de imágenes es un paso crucial en el análisis de pavimentos, donde se utilizan técnicas como la segmentación y la mejora de bordes para resaltar las irregularidades y condiciones del pavimento. Este enfoque permite obtener información detallada que es vital para la gestión y el mantenimiento de las infraestructuras viales (López, 2021).

2.2.5.3 Perfilómetro Láser

El perfilómetro láser es un dispositivo altamente preciso utilizado para medir la rugosidad de las superficies de pavimentos. Este instrumento utiliza tecnología láser para escanear y registrar las irregularidades de la superficie, proporcionando datos que permiten calcular diversos índices de calidad, como el Índice de Regularidad Internacional (IRI). El perfilómetro láser se ha convertido en una herramienta fundamental en el monitoreo de la calidad del pavimento, ya que permite obtener mediciones detalladas y consistentes sin necesidad de contacto físico, lo que minimiza los errores humanos y aumenta la fiabilidad de los resultados. Además, permite realizar mediciones a alta velocidad, lo que facilita la recopilación de datos en grandes tramos de carretera de manera eficiente (Calle, 2022).

El uso del perfilómetro láser en la evaluación de pavimentos se ha incrementado en los últimos años, especialmente en estudios de infraestructura vial en diversas regiones del Perú. Este dispositivo tiene la capacidad de realizar un análisis detallado de las superficies, identificando no solo las irregularidades mayores, como baches o grietas, sino también aquellas de menor escala que podrían generar incomodidad a los conductores. La alta precisión del perfilómetro láser ha permitido que muchos estudios

hidrológicos y viales, que tradicionalmente utilizaban métodos manuales, puedan ahora obtener resultados más confiables y de manera más rápida, lo que mejora la toma de decisiones en los proyectos de mantenimiento de carreteras (Rodríguez y Mendoza, 2021).

El perfilómetro láser no solo se utiliza para determinar el IRI, sino también para evaluar la evolución del estado de las carreteras a lo largo del tiempo. Su capacidad para realizar mediciones de alta precisión lo convierte en una herramienta crucial en la planificación de mantenimientos preventivos y correctivos. Además, su integración con sistemas de información geográfica (SIG) y redes neuronales permite predecir el comportamiento futuro de los pavimentos, optimizando los recursos destinados a la infraestructura vial y mejorando la seguridad de las vías (Gutiérrez, 2020)

Figura 5

Perfilómetro láser (RSP) MK-IV



Fuente. (Dynatest, 2022)

2.3 DEFINICIONES CONCEPTUALES

Algoritmo: Conjunto de instrucciones sistemáticas y ordenadas que permiten resolver problemas específicos mediante procesos computacionales, facilitando la toma de decisiones y el análisis de datos. (Gómez, 2022).

Características del Suelo: Se refieren a propiedades como la granulometría, la capacidad de carga y la plasticidad, que determinan la estabilidad y el desempeño de la subrasante en un pavimento (Fernández, 2019).

Bancos de Materiales: Son fuentes naturales de materiales como grava y arena, utilizados en la construcción de pavimentos. Se evalúan para determinar su calidad y adecuación para el diseño (Pérez, 2020).

Análisis de Tránsito: Examina el tipo y volumen de vehículos que usan una carretera para definir las especificaciones de diseño necesarias para soportar las cargas vehiculares y garantizar su funcionalidad (Rodríguez, 2023).

Volumen de Vehículos: Se refiere a la cantidad total de tráfico que pasa por una sección de carretera en un período determinado, crucial para ajustar el diseño del pavimento a las cargas esperadas (Gómez, 2022).

Red Neuronal: Modelo computacional que simula el funcionamiento del cerebro humano, diseñado para procesar información y aprender de datos, aplicándose en diversas áreas como la predicción y reconocimiento de patrones. (Gómez, 2022).

Subrasante: Es la capa de suelo natural que sirve de base para el pavimento, y su capacidad de carga y estabilidad son fundamentales para el soporte estructural del pavimento (López, 2019).

Capacidad de Carga: Se refiere a su habilidad para soportar las cargas aplicadas sin deformarse excesivamente, y es un factor clave en el diseño de pavimentos para garantizar su durabilidad (Martínez, 2021).

2.4 HIPÓTESIS

2.4.1 Hipótesis general

La aplicación del modelo de Redes Neuronales Artificiales para analizar el pavimento flexible de 1 km de longitud, variará significativamente en comparación con el valor obtenido mediante el Perfilómetro Láser.

2.5 VARIABLES

2.5.1 Variable de Supervisión

El valor del Índice de Regularidad Internacional (IRI) que variará en comparación con el valor obtenido mediante el Perfilómetro Láser.

2.5.2 Variable Asociativa

La aplicación del modelo de Redes Neuronales Artificiales para analizar el pavimento flexible de 1 km de longitud.

2.6 OPERACIONALIZACIÓN DE VARIABLES (DIMENSIONES E INDICADORES)

Tabla 1

Operacionalización de variables

Variables	Definición Operacional	Dimensión	Indicadores	Instrumentos	Escala de medición
Variable Asociativa: Aplicación del modelo de Redes Neuronales	Uso de modelos de redes neuronales artificiales para predecir o clasificar condiciones de pavimentos, en función de variables de entrada como textura, tipo de pavimento, edad, entre otros.	1. Entradas del modelo: Datos de condiciones del pavimento (como tipo de pavimento, edad, condiciones climáticas). 2. Modelo: Estructura y arquitectura de la red neuronal. 3. Predicción: Salida del modelo para estimar la condición del pavimento.	1. Tipo de modelo de Redes Neuronales utilizada	1. Software de modelado	Nominal, Se utiliza para clasificar o categorizar los datos en grupos mutuamente excluyentes, sin ningún orden implícito. (Hernandez Sampieri Roberto, Fernández Collado Carlos y Baptista Lucio María del Pilar, 2018)
			2. Parámetros de entrada del modelo	2. Listado de variables de entrada	
			3. Función de activación seleccionada	3. Documentación técnica	
			4. Algoritmo de aprendizaje utilizado	4. Informe de configuración del modelo	
Variable de Supervisión: Valor del Índice de Regularidad Internacional (IRI)	Indicador que cuantifica la irregularidad de la superficie del pavimento, basado en la medición de la distancia entre las variaciones del perfil longitudinal del pavimento.	1. Valor de IRI: Número obtenido en la medición del perfil del pavimento, que refleja el nivel de irregularidad. 2. Unidades: Se mide en metros por kilómetro (m/km).	1. Valor del IRI obtenido mediante Redes Neuronales	1. Análisis estadístico	
			2. Valor del IRI obtenido mediante Perfilómetro Láser	2. Análisis comparativo	
			3. Diferencia entre ambos valores de IRI	3. Cálculo de diferencia	

CAPÍTULO III

METODOLOGÍA DE LA INVESTIGACIÓN

3.1 TIPO DE INVESTIGACIÓN

3.1.1 Enfoque

La investigación se desarrollará bajo un enfoque cuantitativo, ya que se basa en la recolección y el análisis de datos numéricos asociados al IRI del pavimento flexible. Este enfoque permite medir de manera objetiva la respuesta del pavimento frente a las cargas de tránsito y comparar los valores obtenidos mediante el Perfilómetro Láser con los generados por el modelo de Red Neuronal Artificial.

A partir de estos datos, se aplican procedimientos estadísticos y de correlación que facilitan la interpretación de los resultados y la identificación de diferencias o similitudes entre ambos métodos de evaluación. El enfoque cuantitativo resulta adecuado para este tipo de estudio, porque brinda un marco riguroso para analizar el comportamiento del pavimento, reducir la subjetividad en la interpretación y aportar evidencia sólida para la toma de decisiones en el mantenimiento y gestión de infraestructuras viales.

Este enfoque cuantitativo es fundamental para abordar problemas complejos en la gestión de infraestructuras viales en el Perú (Figuerola, 2021).

3.1.2 Alcance o nivel

El alcance de la investigación corresponde al nivel relacional. Aunque el estudio incluye una descripción del comportamiento del IRI en el pavimento flexible, su propósito principal es analítico, pues busca comparar los valores obtenidos mediante dos metodologías distintas: el Perfilómetro Láser y un modelo de Red Neuronal Artificial. Este nivel permite examinar la relación entre ambos métodos, identificando puntos de coincidencia, discrepancias y el grado de similitud entre los resultados obtenidos durante la verificación.

De esta manera, el análisis no se limita únicamente a caracterizar el estado del pavimento, sino que se enfoca en determinar cómo se comportan las estimaciones del modelo neuronal frente a los valores

reales medidos en campo. El nivel relacional resulta adecuado para estudios que pretenden establecer comparaciones sin buscar causalidad, especialmente en contextos donde se evalúan métodos alternativos de medición o tecnologías emergentes aplicadas a infraestructuras viales.

Según Hernández Sampieri, un estudio correlacional “tiene como finalidad conocer el grado de asociación que existe entre dos o más variables dentro de un contexto específico, sin manipularlas de manera deliberada” (Hernández Sampieri, Fernández Collado, & Baptista, 2014).

3.1.3 Diseño

El diseño de la investigación es no experimental, de tipo transversal y de carácter correlacional–comparativo. Es no experimental porque las variables no se manipulan de forma directa; los datos del IRI se registran tal como se presentan en el pavimento, tanto con el Perfilómetro Láser como con el modelo de Red Neuronal Artificial.

El estudio es transversal debido a que la información se recolecta en un solo momento del tiempo, sobre un tramo de 1 km de pavimento flexible, sin realizar seguimientos posteriores. Bajo estas condiciones, se comparan los resultados obtenidos por ambos métodos para identificar el grado de relación y las diferencias que puedan existir entre ellos.

El carácter correlacional–comparativo se debe a que el propósito central es analizar la relación entre las estimaciones de IRI proporcionadas por la Red Neuronal Artificial y las mediciones realizadas con el Perfilómetro Láser, evaluando si los valores tienden a coincidir o presentan discrepancias significativas. Este tipo de diseño es frecuente en estudios de ingeniería de pavimentos cuando se busca contrastar tecnologías o metodologías alternativas de evaluación en un contexto real de operación.

Este enfoque es útil cuando se busca obtener una instantánea del fenómeno investigado, facilitando la comparación de resultados en un contexto específico y limitado en el tiempo. Tal metodología es común en estudios de ingeniería civil, donde se requiere información puntual sobre el estado de infraestructuras (Aguirre, 2021).

3.2 POBLACIÓN Y MUESTRA

3.2.1 Población

La población se refiere al conjunto completo de elementos o individuos sobre los cuales se desea realizar inferencias. Esta puede ser finita o infinita y es crucial definirla claramente para obtener resultados válidos y representativos. En un estudio, la población abarca todos los sujetos o fenómenos que cumplen con los criterios establecidos por el investigador (Ríos, 2020).

La población estará constituida por todas las vías urbanas de Huánuco con características similares a la Av. Universitaria en cuanto a tráfico y condiciones geotécnicas.

3.2.2 Muestra

La muestra es un subconjunto representativo de la población que se selecciona para realizar el estudio. Su tamaño y características deben reflejar fielmente a la población para asegurar la validez de los resultados. El muestreo puede ser probabilístico o no probabilístico, dependiendo de los objetivos y el diseño del estudio (Pérez, 2019).

La muestra incluirá específicamente la Av. Universitaria, en un tramo de 1 km de longitud delimitado desde la Av. Brasil hasta el Jr. Los paujiles, en el cual tiene que sumar 1 km de longitud.

3.3 TÉCNICAS E INSTRUMENTO DE RECOLECCIÓN DE DATOS.

3.3.1 Para la recolección de datos

3.3.2 Técnicas

La investigación se sustenta en el análisis de modelos de Redes Neuronales Artificiales (RNA) para estimar el Índice de Regularidad Internacional (IRI) del pavimento flexible, considerando los datos obtenidos mediante perfilómetros láser. Según Haykin (2009), en "Neural Networks and Learning Machines", las RNA son eficaces para resolver problemas no lineales al aprender patrones en los datos y predecir resultados con alta precisión. Además, el IRI, como indicador de la condición funcional del pavimento, es medido con alta exactitud mediante perfilómetros láser, tal como destacan Sayers, Gillespie, y Paterson (1986) en "Guidelines for Conducting and Calibrating Road Roughness Measurements".

Las técnicas que se implementarán son:

Selección de Información de Entrada: Se recopilarán y normalizarán los datos obtenidos con perfilómetros láser, incluyendo parámetros como irregularidades longitudinales y textura del pavimento. Esto se fundamenta en Bishop (2006), quien señala que una adecuada selección de variables mejora la capacidad del modelo para evitar el sobreajuste.

Definición de la Arquitectura del Modelo: Se diseñará una RNA tipo feedforward con capas ocultas configuradas según la complejidad del problema, siguiendo la teoría de Hornik, Stinchcombe, y White (1989), quienes argumentan que estas redes pueden aproximar funciones continuas bajo ciertas condiciones.

Evaluación del Modelo: Se validará el modelo mediante técnicas de validación cruzada y métricas como el error cuadrático medio (MSE), siguiendo a Hernández Sampieri et al. (2014) en "Metodología de la investigación", donde se subraya la importancia de validar resultados en estudios cuantitativos.

3.3.3 Instrumentos

La investigación se sustenta en el uso de instrumentos metodológicos y mecánicos que permiten medir, procesar y analizar los datos relacionados con el Índice de Regularidad Internacional (IRI) y el desarrollo de un modelo de Redes Neuronales Artificiales (RNA).

Base Teórica

Medición del IRI: Según Sayers, Gillespie, y Paterson (1986), el perfilómetro láser es un instrumento fundamental para medir las irregularidades longitudinales del pavimento, proporcionando datos precisos para calcular el IRI.

Modelado con RNA: De acuerdo con Haykin (2009), las RNA requieren datos confiables y preprocesados para su entrenamiento, lo que justifica el uso de software y herramientas avanzadas para la organización y análisis de datos.

Validación de Modelos: Hernández Sampieri et al. (2014) destacan la importancia de validar los modelos predictivos mediante técnicas

como la validación cruzada y el cálculo de métricas como el error cuadrático medio (MSE), asegurando la fiabilidad de los resultados.

Instrumentos

3.3.3.1 Perfilómetro Láser:

Función: Mide el perfil longitudinal del pavimento para calcular el IRI.

Relevancia: Es el estándar recomendado por Sayers et al. (1986) para obtener datos fiables sobre la condición funcional del pavimento.

3.3.3.2 GPS Diferencial (DGPS):

Función: Proporciona ubicaciones precisas de los tramos de pavimento estudiados.

Relevancia: Según Vargas y Córdoba (2019), mejora el análisis espacial y la correlación de datos.

3.3.3.3 Vehículo Instrumentado:

Función: Permite integrar el perfilómetro láser y sistemas de adquisición de datos para la recolección de información en campo.

Relevancia: Recomendado por Sayers et al. (1986) para garantizar uniformidad en los registros de medición.

3.3.3.4 Software para Modelado y Análisis:

Python (TensorFlow, Keras) y MATLAB: Facilitan el diseño, entrenamiento y evaluación del modelo neuronal.

Relevancia: Haykin (2009) señala que estas herramientas optimizan la implementación de RNA y la precisión de los resultados.

3.3.3.5 Métricas de Evaluación y Validación:

Errores Cuadrático Medio (MSE) y Validación Cruzada: Evalúan la precisión y confiabilidad del modelo.

Relevancia: Hernández Sampieri et al. (2014) subraya la importancia de estas técnicas en investigaciones cuantitativas.

3.3.3.6 Computadoras de Alto Rendimiento:

Función: Procesar grandes volúmenes de datos y entrenar modelos neuronales.

Relevancia: Según Bishop (2006), el hardware adecuado es esencial para garantizar la eficiencia en el entrenamiento de RNA.

3.3.4 Para la presentación de datos

Para lo correspondiente a la presentación de datos del trabajo de investigación se utilizó lo siguiente:

Tabla 2

Modelo de los instrumentos que se van aplicar en la tesis

Instrumento	Descripción	Fuente de Datos	Método de Recolección	Frecuencia de Recolección
Perfilómetro Láser	Instrumento utilizado para medir de manera precisa la rugosidad del pavimento, generando datos del IRI.	Mediciones obtenidas mediante el perfilómetro láser.	Recolección directa mediante equipo de medición	Una vez al inicio del estudio y periódicamente para comparación.
Modelo de Redes Neuronales Artificiales (RNA)	Proceso computacional para estimar el IRI basado en datos de variables de entrada como condiciones del pavimento.	Datos históricos del pavimento, condiciones climáticas, características del tráfico.	Procesamiento computacional, simulación.	Inicialmente durante la construcción del modelo y a medida que se introduzcan nuevos datos.
Datos de Condiciones Climáticas	Información sobre la temperatura, humedad, lluvia, etc., que pueden influir en el IRI del pavimento.	Estaciones meteorológicas locales o bases de datos.	Recolección de datos secundarios.	Periódica, según disponibilidad de datos.
Datos del Tráfico Vehicular	Información sobre el volumen y tipo de tráfico que influye en el desgaste del pavimento.	Registros de tráfico en la zona de estudio.	Recopilación de datos mediante encuestas o sensores de tráfico.	Continuo, basado en el flujo vehicular.
Observaciones Visuales del Pavimento	Información cualitativa sobre las condiciones visibles del pavimento, como grietas,	Inspección visual directa del pavimento.	Inspección visual periódica.	Durante la recolección de datos en campo.

baches,
deformaciones.

Nota. Se describe los instrumentos que se van a utilizar a medida que se requiera en el trabajo de investigación

3.3.5 Para el análisis e interpretación de los datos

Se utilizarán diversas técnicas para el procesamiento y análisis de la información. Se aplicará un análisis estadístico descriptivo para interpretar las características fundamentales de los datos obtenidos del Perfilómetro Láser, lo que permitirá identificar tendencias y patrones iniciales en el estado del pavimento. Posteriormente, se implementará un modelo de Redes Neuronales Artificiales para procesar los datos, donde se entrenarán las redes con los valores del IRI y se ajustarán los parámetros necesarios para optimizar el rendimiento del modelo. Esto permitirá realizar predicciones sobre el comportamiento del pavimento bajo diferentes condiciones. Finalmente, se llevarán a cabo análisis comparativos entre los resultados obtenidos mediante las Redes Neuronales y los datos del Perfilómetro, utilizando gráficos y tablas para visualizar las variaciones y corroborar la efectividad del modelo propuesto. Estas técnicas proporcionarán una base sólida para tomar decisiones informadas sobre el mantenimiento y mejora de la infraestructura vial en la zona de estudio.

8	0+001.75	363472.77	8898462.71	1943.633
9	0+002.00	363472.86	8898462.47	1943.641
10	0+002.25	363472.96	8898462.24	1943.645
11	0+002.50	363473.05	8898462.01	1943.648
12	0+002.75	363473.14	8898461.78	1943.650
...	...	...	...	...
114	0+028.25	363482.77	8898438.17	1944.181
115	0+028.50	363482.87	8898437.94	1944.174
116	0+028.75	363482.96	8898437.70	1944.167
117	0+029.00	363483.05	8898437.47	1944.163
118	0+029.25	363483.15	8898437.24	1944.158
119	0+029.50	363483.24	8898437.01	1944.146
120	0+029.75	363483.34	8898436.78	1944.144
121	0+030.00	363483.43	8898436.55	1944.138
122	0+030.25	363483.53	8898436.32	1944.128
123	0+030.50	363483.62	8898436.08	1944.121
124	0+030.75	363483.72	8898435.85	1944.114
...	...	...	...	...
1584	0+395.75	363606.76	8898092.29	1949.510
1585	0+396.00	363606.84	8898092.05	1949.518
1586	0+396.25	363606.92	8898091.82	1949.522
1587	0+396.50	363607.00	8898091.58	1949.523
1588	0+396.75	363607.08	8898091.34	1949.528
1589	0+397.00	363607.17	8898091.11	1949.535
4015	1+003.50	363712.60	8897497.73	1952.355
4016	1+003.75	363712.62	8897497.48	1952.353
4017	1+004.00	363712.64	8897497.23	1952.351
4018	1+004.25	363712.66	8897496.99	1952.347
4019	1+004.50	363712.68	8897496.74	1952.341
4020	1+004.75	363712.70	8897496.49	1952.342
4021	1+005.00	363712.72	8897496.24	1952.337
4022	1+005.25	363712.73	8897495.99	1952.334
4023	1+005.50	363712.75	8897495.74	1952.330
4024	1+005.75	363712.77	8897495.49	1952.326
4025	1+006.00	363712.79	8897495.24	1952.325
4026	1+006.25	363712.81	8897494.99	1952.324
4027	1+006.50	363712.83	8897494.74	1952.324
4028	1+006.75	363712.85	8897494.49	1952.316
4029	1+007.00	363712.87	8897494.24	1952.314
4030	1+007.25	363712.89	8897493.99	1952.315
4031	1+007.50	363712.90	8897493.74	1952.311

Nota. Registro de perfilómetro láser para el margen derecho.

Con la realización de un recorrido con el perfilómetro láser se pudo determinar las depresiones y variaciones altitudinales del margen derecho de la vía, el perfilómetro en total realizó 4031 registros registrando a cada 0.25 m.

Tabla 4*Registro de perfilómetro laser – Margen Izquierdo*

REGISTRO DE PERFILÓMETRO LÁSER-MARGEN IZQUIERDO				
# DE REGISTRO	PROGRESIVA	ESTE	NORTE	COTA DE REGISTRO
1	0+000.00	363472.11	8898464.33	1943.609
2	0+000.25	363472.20	8898464.09	1943.613
3	0+000.50	363472.29	8898463.86	1943.612
4	0+000.75	363472.39	8898463.63	1943.619
5	0+001.00	363472.48	8898463.40	1943.626
6	0+001.25	363472.58	8898463.17	1943.624
7	0+001.50	363472.67	8898462.94	1943.628
8	0+001.75	363472.77	8898462.71	1943.634
9	0+002.00	363472.86	8898462.47	1943.641
10	0+002.25	363472.96	8898462.24	1943.643
11	0+002.50	363473.05	8898462.01	1943.645
12	0+002.75	363473.14	8898461.78	1943.648
13	0+003.00	363473.24	8898461.55	1943.651
14	0+003.25	363473.33	8898461.32	1943.658
15	0+003.50	363473.43	8898461.09	1943.659
16	0+003.75	363473.52	8898460.85	1943.662
17	0+004.00	363473.62	8898460.62	1943.671
18	0+004.25	363473.71	8898460.39	1943.672
19	0+004.50	363473.80	8898460.16	1943.677
20	0+004.75	363473.90	8898459.93	1943.678
21	0+005.00	363473.99	8898459.70	1943.681
22	0+005.25	363474.09	8898459.46	1943.685
23	0+005.50	363474.18	8898459.23	1943.687
24	0+005.75	363474.28	8898459.00	1943.690
25	0+006.00	363474.37	8898458.77	1943.700
26	0+006.25	363474.47	8898458.54	1943.702
27	0+006.50	363474.56	8898458.31	1943.703
28	0+006.75	363474.65	8898458.08	1943.712
29	0+007.00	363474.75	8898457.84	1943.713
...	...	...	...	...
71	0+017.50	363478.71	8898448.12	1943.871
72	0+017.75	363478.81	8898447.89	1943.871
73	0+018.00	363478.90	8898447.66	1943.879
74	0+018.25	363479.00	8898447.43	1943.877
75	0+018.50	363479.09	8898447.20	1943.884
76	0+018.75	363479.18	8898446.96	1943.888
77	0+019.00	363479.28	8898446.73	1943.889
78	0+019.25	363479.37	8898446.50	1943.896
79	0+019.50	363479.47	8898446.27	1943.896
80	0+019.75	363479.56	8898446.04	1943.901
81	0+020.00	363479.66	8898445.81	1943.905
82	0+020.25	363479.75	8898445.58	1943.921
83	0+020.50	363479.85	8898445.34	1943.941
84	0+020.75	363479.94	8898445.11	1943.959
85	0+021.00	363480.03	8898444.88	1943.976
86	0+021.25	363480.13	8898444.65	1943.994
...	...	...	...	...
2377	0+594.00	363669.71	8897904.35	1952.321
2378	0+594.25	363669.77	8897904.11	1952.327


2379	0+594.50	363669.84	8897903.87	1952.328
2380	0+594.75	363669.91	8897903.63	1952.335
2381	0+595.00	363669.97	8897903.38	1952.336
2382	0+595.25	363670.04	8897903.14	1952.341
2383	0+595.50	363670.10	8897902.90	1952.342
2384	0+595.75	363670.17	8897902.66	1952.345
2385	0+596.00	363670.24	8897902.42	1952.347
2386	0+596.25	363670.30	8897902.18	1952.351
2387	0+596.50	363670.37	8897901.94	1952.357
2388	0+596.75	363670.44	8897901.70	1952.362
2389	0+597.00	363670.50	8897901.46	1952.365
2390	0+597.25	363670.57	8897901.21	1952.364
2391	0+597.50	363670.63	8897900.97	1952.372
2392	0+597.75	363670.70	8897900.73	1952.372
2393	0+598.00	363670.77	8897900.49	1952.376
2394	0+598.25	363670.83	8897900.25	1952.381
2395	0+598.50	363670.90	8897900.01	1952.386
2396	0+598.75	363670.96	8897899.77	1952.390
4024	1+005.75	363712.77	8897495.49	1952.331
4025	1+006.00	363712.79	8897495.24	1952.327
4026	1+006.25	363712.81	8897494.99	1952.322
4027	1+006.50	363712.83	8897494.74	1952.325
4028	1+006.75	363712.85	8897494.49	1952.320
4029	1+007.00	363712.87	8897494.24	1952.316
4030	1+007.25	363712.89	8897493.99	1952.311
4031	1+007.50	363712.90	8897493.74	1952.308

Nota. Registro de perfilómetro láser para el margen izquierdo.

Con la realización de un recorrido con el perfilómetro láser se pudo determinar las depresiones y variaciones altitudinales del margen derecho de la vía, el perfilómetro en total realizó 4031 registros registrando a cada 0.25 m.

Figura 7

Procesamiento de información




Nota. Modelo de procesamiento PROVAL.

Para el inicio de la interpretación de los valores IRI se tomó como modelo de estimación el presentado por el software PROVAL, con el cual se pudo determinar las variaciones de cota a nivel milimétrico estimando así los valores IRI.

4.1.2 Modelo de estimación IRI

Figura 8

Estimación IRI entre progresivas 0+000 a 0+250




Nota. Análisis de variaciones en perfil IRI.

Del análisis IRI del carril derecho de en la Av. Universitaria en el tramo 0+000 a 0+250 km se identificó que el espectro máximo valor IRI es de 75.36 m/km, para el margen izquierdo el valor IRI determinado es de 69.19 m/km en su punto más crítico.

Figura 9

Estimación IRI entre progresivas 0+250 a 0+500




Nota. Análisis de variaciones en perfil IRI.

Del análisis IRI del carril derecho de en la Av. Universitaria en el tramo 0+250 a 0+500 km se identificó que el espectro máximo valor IRI es de 100.93 m/km, para el margen izquierdo el valor IRI determinado es de 97.93 m/km en su punto más crítico.

Figura 10

Estimación IRI entre progresivas 0+500 a 0+750




Nota. Análisis de variaciones en perfil IRI.

Del análisis IRI del carril derecho de en la Av. Universitaria en el tramo 0+500 a 0+750 km se identificó que el espectro máximo valor IRI es de 227.69 m/km, para el margen izquierdo el valor IRI determinado es de 238.17 m/km en su punto más crítico.

Figura 11

Estimación IRI entre progresivas 0+750 a 1+000




Nota. Análisis de variaciones en perfil IRI.

Del análisis IRI del carril derecho de en la Av. Universitaria en el tramo 0+750 a 1+000 km se identificó que el espectro máximo valor IRI es de 88.40 m/km, para el margen izquierdo el valor IRI determinado es de 85.79 m/km en su punto más crítico.

Figura 12

Estimación promedio de IRI a cada 20 m – Margen Derecho




Nota. Estimación de IRI promedio a cada 20 m.

Del modelo IRI se pudo determinar que en total 18 tramos se encuentran en un estado crítico de coeficiente, en promedio el tramo por el margen derecho se encuentra en un estado moderado de conservación.

Figura 13

Estimación promedio de IRI a cada 20 m – Margen Izquierdo



Nota. Estimación de IRI promedio a cada 20 m.

Del modelo IRI se pudo determinar que en total 17 tramos se encuentran en un estado crítico de coeficiente, en promedio el tramo por el margen izquierdo se encuentra en un estado moderado de conservación.

4.1.3 Información de entrada para el modelo neuronal

Para la composición neuronal del modelo de determinación de IRI se tomaron en cuenta la metodología del PCI en la cual se caracterizan por carriles con la finalidad de presentar una correlación, en el manual del PCI se tomaron en cuenta 20 diferentes tipos de daños a inventariar para ambos carriles.

Tabla 5

Características a inventariar en el tramo


INVENTARIO DE DAÑOS SEGÚN PCI	
N°	Tipo
1	Piel de cocodrilo
2	Exudación
3	Agrietamiento en bloque
4	Abultamiento / Hundimiento
5	Corrugación
6	Depresión
7	Grietas de borde
8	Grietas de reflexión de juntas
9	Desnivel Carril / Berma
10	Grietas Longitudinal y transversal
11	Parcheo
12	Pulimento de agregados
13	Huecos
14	Cruce de vía férrea
15	Ahuellamiento
16	Desplazamiento
17	Grieta parabólica
18	Hinchamiento
19	Desprendimiento
20	Desgaste

Nota. Ítems evaluados en la caracterización.

Con la finalidad de caracterizar de manera visual los tramos analizados, se elaboró una lista de características planteadas por el análisis de PSI para pavimentos, cada uno de ellos fueron considerados para los tramos tomados a cada 20 m.

Figura 14

Características PSI carril derecho por progresiva




Nota. Consideración de los 20 ítems de caracterización PSI.

Con la caracterización de las características de deterioro en el recorrido de la avenida universitaria se pudo determinar una caracterización completa de los 20 ítems para la caracterización de la vía derecha.

Figura 15

Características PSI carril izquierdo por progresiva



Nota. Consideración de los 20 ítems de caracterización PSI.

Con la caracterización de las características de deterioro en el recorrido de la avenida universitaria se pudo determinar una caracterización completa de los 20 ítems para la caracterización de la vía izquierda.

Con la identificación de cada una de las características que componen al modelo PSI se procedió a disminuir las variables con la finalidad de optimizar el modelo neuronal planteado en la investigación.

4.1.4 Arquitectura del modelo neuronal

Tabla 6

Modelo de variables para la arquitectura del modelo

Agrupación de variables			
Nombre	Componentes		
V1	Piel de cocodrilo	Agrietamiento en bloque	
V2	Exudación	Corrugación	
V3	Abultamiento / Hundimiento	Depresión	Ahuellamiento
V4	Desnivel Carril / Berma	Huecos	Desgaste
V5	Grietas de borde		

Nota. Agrupación de variables.

A fin de disminuir las variables de la red neuronal para una mayor eficiencia en el proceso de iteración se agruparon componentes de la metodología PSI que presenten características similares y que se hayan identificado en el área de interés, obteniendo finalmente un total de 05 variables analizadas.

Tabla 7

Análisis de tendencias margen derecho

Análisis estadístico de datos											
Nombre		Componentes		Media	Mediana	Desv Estándar	Varianza	Coef Curtosis	Coef. Asim.	Min	Max
V1	Piel de cocodrilo	Agrietamiento en bloque		44.95%	41.32%	17.15%	2.94%	0.30	1.03	25.18%	85.88%
V2	Exudación	Corrugación		45.24%	46.99%	17.84%	3.18%	0.96	0.79	21.59%	93.00%
V3	Abultamiento / Hundimiento	Depresión	Ahuellamiento	48.99%	37.65%	24.95%	6.23%	-1.08	0.74	22.89%	98.27%
V4	Desnivel Carril / Berma	Huecos	Desgaste	46.91%	42.36%	22.02%	4.85%	0.07	1.03	21.88%	99.13%
V5	Grietas de borde			40.01%	32.30%	19.49%	3.80%	0.57	1.37	21.83%	75.45%

Nota. Análisis estadístico de los valores recolectados.

El análisis estadístico permitió evaluar la distribución y variabilidad de los diferentes tipos de deterioro en la superficie analizada. Se identificó que V3 (Abultamiento, Hundimiento, Depresión y Ahuellamiento) presentó la mayor afectación promedio (48.99%), mientras que V5 (Grietas de borde) tuvo la menor incidencia (40.01%). En cuanto a la variabilidad, V3 mostró la mayor dispersión, con una desviación estándar de 24.95%, lo que evidenció diferencias significativas en su distribución. En contraste, V1 (Piel de cocodrilo y

Agrietamiento en bloque) tuvo la menor variabilidad (17.15%), reflejando una afectación más homogénea. El análisis de curtosis indicó que V3 presentó una distribución más plana (-1.08), mientras que V2 (Exudación y Corrugación) tuvo la distribución más concentrada (0.96). Asimismo, la mayoría de las variables mostraron una asimetría positiva, lo que sugirió la presencia de valores atípicos altos en algunas zonas. Los valores extremos oscilaron entre 21.59% (mínimo en V2) y 99.13% (máximo en V4 - Desnivel Carril/Berma, Huecos y Desgaste), lo que reflejó variaciones significativas en la presencia de estos daños. En conclusión, los resultados evidenciaron que V3 fue el tipo de deterioro más recurrente, mientras que V5 tuvo la menor incidencia. La marcada variabilidad en algunas categorías sugirió la necesidad de intervenciones focalizadas en zonas con altos niveles de afectación.

Tabla 8

Análisis de tendencias margen izquierdo

Análisis estadístico de datos											
Nombre		Componentes		Media	Mediana	Desv Estándar	Varianza	Coef Curtosis	Coef. Asim.	Min	Max
V1	Piel de cocodrilo	Agrietamiento en bloque		41.00%	35.88%	18.07%	3.27%	0.40	1.21	21.36%	81.22%
V2	Exudación	Corrugación		42.26%	35.23%	18.41%	3.39%	0.05	1.10	23.59%	83.94%
V3	Abultamiento / Hundimiento	Depresión	Ahuellamiento	47.03%	43.30%	21.66%	4.69%	0.03	0.97	21.38%	98.63%
V4	Desnivel Carril / Berma	Huecos	Desgaste	45.08%	41.94%	17.75%	3.15%	1.90	1.28	22.54%	94.95%
V5	Grietas de borde			47.50%	43.62%	23.75%	5.64%	1.38	1.42	21.72%	97.60%

Nota. Análisis estadístico de los valores recolectados.


El análisis estadístico de los datos permitió evaluar la distribución y variabilidad de los distintos tipos de deterioro presentes en la superficie analizada. Se observó que V5 (Grietas de borde) presentó la mayor afectación promedio (47.50%), mientras que V1 (Piel de cocodrilo y Agrietamiento en bloque) tuvo la menor incidencia (41.00%). En cuanto a la variabilidad, V5 mostró la mayor dispersión, con una desviación estándar de 23.75% y una varianza de 5.64%, lo que indicó una alta heterogeneidad en su distribución. En contraste, V4 (Desnivel Carril/Berma, Huecos y Desgaste) presentó la menor variabilidad (17.75% de desviación estándar y 3.15% de varianza), sugiriendo una distribución más uniforme. El análisis de curtosis reveló que V4 tuvo la

distribución más apuntada (1.90), mientras que V3 (Abultamiento, Hundimiento, Depresión y Ahuellamiento) presentó una distribución cercana a la normal (0.03). La asimetría positiva en todas las variables indicó una mayor concentración de valores bajos, con la presencia de valores extremos elevados, siendo V5 la de mayor asimetría (1.42). Los valores extremos oscilaron entre 21.36% (mínimo en V1) y 98.63% (máximo en V3), lo que reflejó importantes diferencias en la afectación de cada variable.

4.1.5 Métodos de aprendizaje de red neuronal

Figura 16

Esquema típico de red neuronal



Nota. Modelo de red neuronal básico.

Para el planteamiento de la red neuronal se esquematizaron los procesos para la programación de la red neuronal, en ella se identificaron las 5 variables agrupadas en el ítem anterior y la cantidad de capas y de neuronas se determinó en el proceso posterior con la finalidad de ajustar el modelo más preciso con los recursos recolectados.

Tabla 9

Datos de entrada para la red neuronal

Estimación promedio de variables					
Progresiva	V1	V2	V3	V4	V5
0+000.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+020.00	81.69%	46.45%	40.89%	61.85%	74.78%
0+040.00	34.00%	33.90%	0.00%	31.64%	0.00%
0+060.00	0.00%	0.00%	10.78%	7.48%	27.64%

0+080.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+100.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+120.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+140.00	0.00%	10.79%	15.43%	23.48%	0.00%
0+160.00	51.55%	42.24%	54.91%	74.03%	0.00%
0+180.00	15.07%	0.00%	6.90%	20.10%	25.09%
0+200.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+220.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+240.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+260.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+280.00	32.13%	67.49%	58.09%	37.87%	0.00%
0+300.00	22.88%	11.16%	16.48%	25.96%	39.39%
0+320.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+340.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+360.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+380.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+400.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+420.00	17.83%	40.39%	10.74%	46.15%	75.45%
0+440.00	36.83%	0.00%	25.58%	11.96%	0.00%
0+460.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+480.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+500.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+520.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+540.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+560.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+580.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+600.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+620.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+640.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+660.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+680.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+700.00	0.00%	24.49%	77.93%	31.20%	21.83%
0+720.00	29.06%	41.56%	17.12%	29.57%	0.00%
0+740.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+760.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+780.00	32.93%	23.92%	21.04%	30.57%	20.90%
0+800.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+820.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+840.00	46.80%	50.85%	74.36%	52.79%	35.64%
0+860.00	43.35%	11.74%	22.96%	25.97%	28.71%
0+880.00	20.39%	40.74%	35.75%	27.26%	41.72%
0+900.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+920.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+940.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+960.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+980.00	0.00%	0.00%	0.00%	0.00%	0.00%
1+000.00	17.75%	43.96%	6.86%	8.38%	0.00%

Nota. Registro de promedio de variables por progresiva.

Con el modelo IRI se estimaron los valores promedio por agrupación de variables, obteniendo así un total de 51 registros por

variables que fueron tomados del carril derecho del análisis, con en total se tienen un total de 255 datos de ingreso para la red neuronal.

Tabla 10

Librerías aplicadas para la generación del modelo de red neuronal

Código	Descripción
import tensorflow as tf	Importa TensorFlow, la biblioteca para construir y entrenar la red neuronal.
import numpy as np	
V1 = np.array([...], dtype=float)	Importa NumPy, usado para manipular arrays numéricos.
V2 = np.array([...], dtype=float)	
V3 = np.array([...], dtype=float)	
V4 = np.array([...], dtype=float)	
V5 = np.array([...], dtype=float)	
IRI = np.array([...], dtype=float)	Define los datos de entrada (V1-V5) y la variable objetivo (IRI) como arrays NumPy.
min_length = min(len(V1), len(V2), len(V3), len(V4), len(V5))	
V1 = V1[:min_length]	Ajusta la longitud de los vectores de entrada al mínimo tamaño común para evitar errores en el modelo.
V2 = V2[:min_length]	
V3 = V3[:min_length]	
V4 = V4[:min_length]	
V5 = V5[:min_length]	
X = np.stack([V1, V2, V3, V4, V5], axis=1)	Construye la matriz de entrada combinando los vectores en una estructura adecuada para la red neuronal.
X = X.reshape(-1, 5)	
oculta1 = tf.keras.layers.Dense(units=6, input_shape=[5])	Capa oculta 1 con 6 neuronas y 5 entradas.
oculta2 = tf.keras.layers.Dense(units=6)	Capa oculta 2 con 6 neuronas.
salida = tf.keras.layers.Dense(units=1)	Capa de salida con una neurona, que generará la predicción del IRI.
modelo = tf.keras.Sequential([oculta1, oculta2, salida])	Define la arquitectura de la red neuronal como una secuencia de capas.
modelo.compile(optimizer=tf.keras.optimizers.Adam(0.1), loss='mean_squared_error')	Compila el modelo con el optimizador Adam y la función de pérdida de error cuadrático medio.
print("Comenzando entrenamiento...")	Mensaje para indicar el inicio del entrenamiento.
historial = modelo.fit(X, IRI, epochs=1000, verbose=False)	Entrena el modelo con los datos de entrada y salida durante 1000 épocas.
print("Modelo entrenado!")	Mensaje para indicar que el entrenamiento ha finalizado.

```
predicciones = modelo.predict(X)
```

```
coeficiente_correlacion = np.corrcoef(IRI,  
predicciones.flatten())[0, 1]
```

Usa el modelo entrenado para predecir valores de IRI. Calcula el coeficiente de correlación entre las predicciones y los valores reales de IRI.


Nota. Programación necesaria para el modelo de red neuronal.

Las líneas de código fueron utilizadas en el software Google Colab que es de libre acceso y se basa en la utilización de una computadora virtual ejecutada en la nube de sus servidores, los códigos presentados en la tabla fueron necesarios para el planteamiento de la red neuronal para la estimación del coeficiente IRI.

4.1.6 Función de activación

Figura 17

Esquema de primer entrenamiento




Nota. Modelo de entrenamiento de la red neuronal.

Para el primer entrenamiento se estableció una topología que se componen de las 5 variables con 2 capas de 6 neuronas cada uno y con un total de 1000 iteraciones para la estimación del valor IRI del pavimento en el carril derecho.

Figura 18

Gráfica de erro cuadrático medio




Nota. Grafica de error cuadrático medio del entrenamiento.

De la figura se puede identificar que para la iteración 50 el error estimado se genera como constante evidenciando que ya encontró un patrón al cual corresponder la red neuronal.

Figura 19

Correlación de valores estimados y generados




Nota. Correlación entre red neuronal y valores recolectados.

En la correlación entre los valores obtenidos y los valores estimados por la red neuronal se pudo identificar que hay un coeficiente de correlación de 0.94 siendo óptimo para la red neuronal en el carril derecho de análisis.

Figura 20

Comparación con el carril izquierdo




Nota. Aplicación de red neuronal en carril izquierdo.

Con la aplicación de la red neuronal con los datos de entrada del carril izquierdo se pudo determinar que el coeficiente de correlación es de 0.34 siendo este muy bajo en su precisión.

Figura 21

Esquema del segundo entrenamiento




Nota. Modelo de entrenamiento de la red neuronal.

Para el segundo entrenamiento se estableció una topología que se componen de las 5 variables con 3 capas de 10 neuronas cada una y con un total de 1000 iteraciones para la estimación del valor IRI del pavimento en el carril derecho.

Figura 22

Gráfica de erro cuadrático medio




Nota. Grafica de error cuadrático medio del entrenamiento.

De la figura se puede identificar que para la iteración 25 el error estimado se genera como constante evidenciando que ya encontró un patrón al cual corresponder la red neuronal.

Figura 23

Correlación de valores estimados y generados




Nota. Correlación entre red neuronal y valores recolectados.

En la correlación entre los valores obtenidos y los valores estimados por la red neuronal se pudo identificar que hay un coeficiente

de correlación de 0.94 siendo óptimo para la red neuronal en el carril derecho de análisis.

Figura 24

Comparación con el carril izquierdo




Nota. Aplicación de red neuronal en carril izquierdo.

Con la aplicación de la red neuronal con los datos de entrada del carril izquierdo se pudo determinar que el coeficiente de correlación es de 0.34 siendo este muy bajo en su precisión.

Figura 25

Esquema del tercer entrenamiento




Nota. Modelo de entrenamiento de la red neuronal.

Para el tercer entrenamiento se estableció una topología que se componen de las 5 variables con 5 capas de 25 neuronas cada una y con un total de 1000 iteraciones para la estimación del valor IRI del pavimento en el carril derecho.

Figura 26

Gráfica de erro cuadrático medio




Nota. Grafica de error cuadrático medio del entrenamiento.

De la figura se puede identificar que para la iteración 10 el error estimado se genera como constante evidenciando que ya encontró un patrón al cual corresponder la red neuronal.

Figura 27

Correlación de valores estimados y generados




Nota. Correlación entre red neuronal y valores recolectados.

En la correlación entre los valores obtenidos y los valores estimados por la red neuronal se pudo identificar que hay un coeficiente

de correlación de 0.94 siendo óptimo para la red neuronal en el carril derecho de análisis.

Figura 28

Comparación con el carril izquierdo




Nota. Aplicación de red neuronal en carril izquierdo.

Con la aplicación de la red neuronal con los datos de entrada del carril izquierdo se pudo determinar que el coeficiente de correlación es de 0.34 siendo este muy bajo en su precisión.

Se identificó que al incrementar las capas y las neuronas no hay una variación significativa, con ello la última iteración se elaboró con 1 capa y 10 neuronas para identificar la variación.

Figura 29

Esquema del cuarto entrenamiento




Nota. Modelo de entrenamiento de la red neuronal.

Para el cuarto entrenamiento se estableció una topología que se componen de las 5 variables con 1 capas de 10 neuronas cada una y

con un total de 1000 iteraciones para la estimación del valor IRI del pavimento en el carril derecho.

Figura 30

Gráfica de erro cuadrático medio




Nota. Grafica de error cuadrático medio del entrenamiento.

De la figura se puede identificar que para la iteración 60 el error estimado se genera como constante evidenciando que ya encontró un patrón al cual corresponder la red neuronal.

Figura 31

Correlación de valores estimados y generados




Nota. Correlación entre red neuronal y valores recolectados.

En la correlación entre los valores obtenidos y los valores estimados por la red neuronal se pudo identificar que hay un coeficiente de correlación de 0.94 siendo óptimo para la red neuronal en el carril derecho de análisis.

Figura 32

Comparación con el carril izquierdo




Nota. Aplicación de red neuronal en carril izquierdo.

Con la aplicación de la red neuronal con los datos de entrada del carril izquierdo se pudo determinar que el coeficiente de correlación es de 0.34 siendo este muy bajo en su precisión.

Figura 33

Comparación de modelos de entrenamiento – Carril derecho




Nota. Comparación de coeficiente de correlación entre modelos.

Para el análisis de correlación se pudo determinar el coeficiente de correlación para los modelos son de 0.936155, 0.936076, 0.936045 y 0.936089 para el primer, segundo, tercer y cuarto entrenamiento, con ello se pudo determinar que el mejor entrenamiento de red neuronal lo presenta en primer modelo con 2 capas y 12 neuronas.

Figura 34

Comparación de modelos de verificación – Carril Izquierdo



Nota. Comparación de coeficiente de correlación entre modelos.

Para el análisis de correlación se pudo determinar el coeficiente de correlación para los modelos son de 0.343161, 0.344191, 0.342432 y 0.342469 para el primer, segundo, tercer y cuarto entrenamiento, con ello se pudo determinar que los mejores valores predichos los presenta el segundo modelo con 3 capas y 30 neuronas.


Con los resultados obtenidos se pudo evidenciar que si bien los modelos de entrenamiento presentan un ajuste adecuado, al ser sometidos a un modelo de verificación con los valores IRI del carril contiguo estos ajustes se desploman llegando en promedio al 0.34 en factor de correlación promedio clasificando así al modelo como muy bajo en sus correlaciones y descartando un ajuste adecuado.

4.2 CONTRASTACIÓN DE HIPÓTESIS Y PRUEBA DE HIPÓTESIS

Hg: La aplicación del modelo de Redes Neuronales Artificiales para analizar el pavimento flexible de 1 km de longitud, variará significativamente en comparación con el valor obtenido mediante el Perfilómetro Láser.

Figura 35

Comparación de modelos de verificación – Carril Izquierdo



Nota. Comparación de coeficiente de correlación entre modelos.

Para contrastar la hipótesis general se realizó una comparación entre los valores del IRI estimados por los distintos modelos de Red Neuronal Artificial y los resultados medidos con el Perfilómetro Láser. En el análisis de correlación se identificaron valores de 0.343161, 0.344191, 0.342432 y 0.342469 para los modelos correspondientes al primer, segundo, tercer y cuarto entrenamiento. Entre ellos, el segundo modelo mostró un desempeño ligeramente superior, con un ajuste más estable durante la fase de entrenamiento con 3 capas y 30 neuronas.

Sin embargo, la variación más evidente se presenta en la fase de validación. A lo largo del kilómetro analizado, los valores estimados por la red difieren de manera significativa respecto a los valores reales obtenidos con el Perfilómetro Láser. El coeficiente de correlación promedio, cercano a 0.34, muestra que el modelo no logra reproducir con precisión el comportamiento del IRI en un tramo que no formó parte del entrenamiento.

Esta diferencia marcada entre el desempeño en la etapa de entrenamiento y la etapa de validación evidencia que los resultados de ambos métodos no son equivalentes. Desde un enfoque descriptivo-comparativo, esta discrepancia resulta suficiente para dar por contrastada la hipótesis general: la estimación del IRI mediante Redes Neuronales Artificiales presenta una variación significativa respecto a los valores determinados por el Perfilómetro Láser bajo las condiciones del estudio.

Si bien no se aplicó una prueba estadística formal para obtener un valor p , la evidencia empírica es clara al mostrar que la RNA no reproduce con fidelidad los valores medidos en la verificación, confirmando así la hipótesis general planteada.

CAPÍTULO V

DISCUSIÓN DE RESULTADOS

Mayorga (2023), en su investigación sobre el reconocimiento y clasificación de daños en pavimentos de Sogamoso, implementó un modelo de aprendizaje automático basado en imágenes y datos de sensores, logrando una precisión del 92% en la identificación de fallas. La combinación de imágenes capturadas por cámaras instaladas en vehículos y datos de vibración obtenidos mediante acelerómetros permitió mejorar en un 12% la precisión del modelo en comparación con el uso exclusivo de imágenes. Además, el tiempo de procesamiento de cada imagen fue de 1.8 segundos, lo que demostró la viabilidad del modelo para su aplicación en tiempo real. Este antecedente evidenció que la adecuada selección de variables de entrada y la calibración de los parámetros del modelo son aspectos clave para optimizar la clasificación y predicción de daños en pavimentos. En la presente investigación, se observó que la variación del Índice de Regularidad Internacional (IRI) mediante el modelo de redes neuronales presentó altos coeficientes de correlación en la fase de entrenamiento (superiores a 0.93), pero valores significativamente menores en la etapa de verificación (alrededor de 0.34). Este resultado sugiere que el modelo requiere ajustes en su proceso de validación, lo que concuerda con el estudio de Mayorga (2023), donde la precisión del modelo se optimizó mediante el uso de datos complementarios. La inclusión de información adicional, como mediciones de vibración o imágenes del pavimento, podría mejorar la capacidad de generalización del modelo en la predicción del IRI. Asimismo, la clasificación de defectos del pavimento en cinco categorías permitió estructurar de manera eficiente los datos de entrada para la red neuronal. Este enfoque es similar al aplicado por Mayorga (2023), quien integró diversas fuentes de información para mejorar la detección de fallas. En nuestro estudio, se identificaron cinco grupos de defectos: fisuras estructurales, deformaciones superficiales, irregularidades verticales, desgaste y desniveles, y grietas en los bordes. Esta categorización facilita la identificación de patrones en la variación del IRI y contribuye a mejorar la precisión del modelo.

Inchicsana (2024), en su estudio sobre la aplicación de Deep Learning para la detección de anomalías en pavimentos en el distrito de Socabaya, demostró que el uso de redes neuronales convolucionales (CNN) permite identificar con alta precisión diversas fallas en la superficie del pavimento, alcanzando un 94% de exactitud en la clasificación de daños. La combinación de imágenes capturadas por cámaras en vehículos y el uso de técnicas de aumento de datos mejoró en un 10% la precisión del modelo, lo que evidenció la relevancia de un conjunto de datos balanceado y de estrategias de preprocesamiento para optimizar la detección de anomalías. Además, el modelo desarrollado logró un tiempo de procesamiento de 1.6 segundos por imagen, lo que confirma su viabilidad para la inspección automatizada en tiempo real. En la presente investigación, se identificaron cinco categorías principales de defectos en el pavimento mediante un modelo de redes neuronales, con coeficientes de correlación elevados en la fase de entrenamiento (mayores a 0.93), pero con una disminución significativa en la etapa de verificación (alrededor de 0.34). Esto sugiere la necesidad de optimizar el proceso de validación del modelo, tal como se observó en el estudio de Inchicsana (2024), donde el uso de técnicas de aumento de datos permitió mejorar la capacidad de generalización del modelo. En este sentido, la inclusión de estrategias similares en nuestra investigación podría contribuir a reducir la diferencia de rendimiento entre las fases de entrenamiento y prueba, mejorando la robustez del sistema. Asimismo, la clasificación de defectos en fisuras estructurales, deformaciones superficiales, irregularidades verticales, desgaste y grietas en los bordes permitió estructurar adecuadamente los datos de entrada para la red neuronal. Este enfoque guarda similitud con el modelo desarrollado por Inchicsana (2024), donde la correcta categorización de las anomalías y el etiquetado preciso de los datos fueron aspectos clave para mejorar la precisión en la detección de fallas. En nuestra investigación, la implementación de una clasificación estructurada ha facilitado la identificación de patrones en la variación del Índice de Regularidad Internacional (IRI), lo que resulta fundamental para la toma de decisiones en la gestión del mantenimiento vial.

CONCLUSIONES

Del análisis de la variación del Índice de Regularidad Internacional (IRI) con el modelo de redes neuronales se pudo concluir que para el modelo de entrenamiento se obtuvieron los coeficientes de correlación de 0.936155, 0.936076, 0.936045 y 0.936089 para el primer, segundo, tercer y cuarto modelo respectivamente, mientras que para los modelos de verificación se obtuvieron los siguientes coeficientes de correlación 0.343161, 0.344191, 0.342432 y 0.342469 respectivamente. Con ello se pudo verificar que el modelo neuronal requiere de un ajuste en su etapa de validación.

La identificación de la información de entrada para el modelo neuronal permite clasificar los defectos del pavimento en cinco categorías según su naturaleza y efectos. V1 abarca fisuras estructurales, V2 deformaciones superficiales, V3 irregularidades verticales, V4 desgaste y desniveles, y V5 grietas en los bordes de la calzada.

De la definición de la organización de la arquitectura del modelo neuronal se concluyó que, se aplicaron 4 modelos de diferentes arquitecturas, siendo el primero de 02 capas y 12 neuronas, el segundo modelo de 03 capas y 30 neuronas, el tercer modelo de 5 capas y 125 neuronas y el cuarto modelo de 01 capa y 10 neuronas obteniendo para cada uno diferentes ajustes.

Del establecimiento del mejor método de aprendizaje se pudo concluir que el aprendizaje para las redes neuronales es la óptima para la generación de una red con una gran cantidad de valores numéricos como se aplicó en esta investigación debido a su consideración de fallos en cada una de sus correlaciones entre capas y neuronas establecidas del modelo.

De la identificación de la función de activación en la implementación del modelo neuronal se pudo concluir que la utilización del modelo Tensorflow se acomoda mejor a la red de aprendizaje numérico a partir de matrices de correlación neuronal presentando un ajuste óptimo en las iteraciones de entrenamiento.

RECOMENDACIONES

Se recomienda optimizar los parámetros del modelo y aumentar la cantidad de datos de validación para mejorar su capacidad de generalización, la utilización de los registros de densidad vehicular puede mejorar el ajuste del modelo siendo este un factor constante de deterioro en cualquier tipo de vía.

Se recomienda incrementar la cantidad de variables de entrada del modelo neuronal ya que a más información de ingreso mayor será el reajuste para los modelos de validación.

Se recomienda seleccionar la arquitectura con mejor desempeño y optimizarla con técnicas como regularización y ajuste de hiperparámetros, a ello se le incluye también la actualización del código ya que al ser una tecnología en constante evolución la arquitectura de la red puede ser optimizada a futuro.

Se recomienda explorar diferentes algoritmos de optimización para mejorar la convergencia y precisión del modelo.

Se recomienda continuar utilizando TensorFlow y evaluar diferentes funciones de activación para mejorar el desempeño del modelo en distintos escenarios

REFERENCIAS BIBLIOGRÁFICAS

- Aguirre, J. C. (2021). *Metodología de la investigación en ingeniería civil*. Lima: Universitaria.
- ANA. (2018). *Manual de Diseño y Construcción de Pavimentos Semiflexibles*. Lima: Ministerio de Transportes y Comunicaciones del Perú.
- Arteaga Villanueva, G. D., & Noriega Poma, V. H. (2019). *Análisis de la variación del Índice de Regularidad Internacional (IRI) en función de variables constructivas y geométricas en vías menores*. Lima: Universidad Ricardo Palma.
- Calderón, J., Alvarado, P, & Salazar, R. (2022). *"Evaluación de Métodos de Análisis en la Ingeniería Civil", , , Editorial*. Lima - Perú: Ingeniería.
- Calle, J. M. (2022). *Aplicación del perfilómetro láser en la evaluación de pavimentos urbanos en Perú*. Lima: Editorial Técnica de Ingeniería.
- Chavez, J. C. (2019). *Tecnologías y mantenimiento de pavimentos flexibles en el Perú*. Lima: Universidad Nacional Agraria La Molina.
- Chino Mestas, J. R., & Inchicsana Huamani, P. J. (2024). *Aplicación de Deep Learning para la detección de anomalías en pavimento en una zona del distrito de "Socabaya", Arequipa 2024*. Lima: Universidad César Vallejo.
- CPA. (2016). *Guía para el Diseño y Construcción de Pavimentos Asfálticos*. Lima: Instituto Peruano del Asfalto.
- Dynatest. (2022). Obtenido de <https://www.dynatestlatam.com/perfilometro-laser-rsp-mk-iv/>
- Fernández Huamán, M. E. (2019). *Análisis de Suelos para Pavimentos*. Lima: Editorial Científica.
- Fernández, C., & López, R. (2021). *El camino hacia el Deep Learning moderno*. Cusco: Editorial Técnica.
- Figuroa B. , J. A. (2021). *Metodología de la investigación: un enfoque cuantitativo*. Lima: San Marcos.
- García Martínez, L. (2018). *Detección de anomalías en sistemas de información*. Ciudad de México.: Editorial Tecnológica.
- Gómez Silva, R. (2022). *Pavimentos Semiflexibles: Diseño y Construcción en Perú*. Perú: Ingenieros del Perú.

- Gutiérrez, A. M. (2020). *Tecnologías avanzadas para la evaluación de pavimentos flexibles en el Perú*. Cusco: Editorial Técnica de Vías y Transportes.
- Hernandez Sampieri Roberto, Fernández Collado Carlos y Baptista Lucio María del Pilar. (2018). *Metodología De La Investigación*. Mc Graw Hill. doi:<https://www.esup.edu.pe/wp-content/uploads/2020/12/2.%20Hernandez,%20Fernandez%20y%20Baptista-Metodolog%C3%ADa%20Investigacion%20Cientifica%206ta%20ed.pdf>
- INEI. (2023). *Estado de la Infraestructura Vial en el Perú*. Lima: Instituto Nacional de Estadística e Informática.
- Kumar, A. (2021). *Image Processing Techniques for Pavement Evaluation*. Nueva Delhi: Springer.
- Li, J. (2019). *Computer Vision Applications in Pavement Analysis*. Pekín: Elsevier.
- López Salazar, F. (2019). *Caracterización de Subrasantes para Pavimentos*. Lima: Ingeniería Nacional.
- López,, M. (2021). *Innovaciones en el Monitoreo de Pavimentos mediante Imágenes*. Santiago: Ediciones Técnicas de Chile.
- Martínez Celis, L. E. (05 de Diciembre de 2024). *El ingeniero*. Obtenido de Noticias y blog de ingeniería: <https://noticiaselingenero.com/que-es-un-pavimento-flexible/>
- Martínez Huerta, J. L. (2021). *Capacidad de Carga y Diseño de Pavimentos*. Lima: Científica y Técnica.
- Martínez, A. (2023). *Métodos Avanzados en la Evaluación de Pavimentos a través de Imágenes*. Bogotá : Universidad Nacional de Colombia.
- Mayorga Ballesteros, D. C. (2023). *Diseño de un modelo de aprendizaje de máquina para reconocimiento y clasificación de daños en pavimento para vías de Sogamoso*. Medellín: Universidad Nacional de Colombia.
- MTC. (2020). *Manual de Carreteras: Mantenimiento Rutinario y Periódico*. Lima: Fondo Editorial del Ministerio de Transportes y Comunicaciones del Perú.

- MTC. (2022). *Uso de tecnologías en la gestión vial*. Lima. Ministerio de Transportes y Comunicaciones.
- Municipalidad Provincial de Huánuco. (2023). *Informe técnico sobre el estado del pavimento de la Av. Universitaria*. Huánuco: Municipalidad Provincial de Huánuco.
- Patel, R. (2021). *Anomaly Detection in Time-Series Data Using Convolutional Neural Networks*. Nueva Delhi: Wiley.
- PIARC. (2019). *Evaluación del IRI en Carreteras*. París: Asociación Mundial de Carreteras.
- Rajalingappaa, S. (2019). *Deep Learning for Computer Vision*. Birmingham: Packt Publishing.
- Rosebrock, A. (2017). *Deep Learning for Computer Vision with Python*. San Francisco: PyImageSearch.
- Torres, J. (2022). *Advancements in Anomaly Detection Using Deep Learning Techniques*. Madrid: Elsevier.

como citar este trabajo de investigación

Alvarez Robles, F. H. (2025). *Análisis de la variación del valor del índice de regularidad internacional (IRI) del pavimento flexible de 1 km de longitud mediante redes neuronales y el perfilómetro láser, 2025* [Tesis de pregrado, Universidad de Huánuco]. Repositorio Institucional UDH. <http://>

ANEXOS

Anexo 1: Resolución de Aprobación del proyecto de trabajo de investigación

UNIVERSIDAD DE HUÁNUCO

Facultad de Ingeniería

RESOLUCIÓN Nº 0285-2025-D-FI-UDH

Huánuco, 20 de febrero de 2025

Visto, el Oficio N° 0175-2025-C-PAIC-FI-UDH, mediante el cual el Coordinador Académico de Ingeniería Civil, remite el dictamen de los jurados revisores, del Trabajo de Investigación (Tesis) intitulado: "ANÁLISIS DE LA VARIACIÓN DEL VALOR DEL ÍNDICE DE REGULARIDAD INTERNACIONAL (IRI) DEL PAVIMENTO FLEXIBLE DE 1 KM DE LONGITUD MEDIANTE REDES NEURONALES Y EL PERFILÓMETRO LÁSER, 2025", presentado por el (la) Bach. Franck Hussein ALVAREZ ROBLES.

CONSIDERANDO:

Que, mediante Resolución N° 006-2001-R-AU-UDH, de fecha 24 de julio de 2001, se crea la Facultad de Ingeniería, y;

Que, mediante Resolución de Consejo Directivo N° 076-2019-SUNEDU/CD, de fecha 05 de junio de 2019, otorga la Licencia a la Universidad de Huánuco para ofrecer el servicio educativo superior universitario, y;

Que, mediante Resolución N° 1845-2024-D-FI-UDH, de fecha 28 de agosto de 2024, perteneciente al Bach. Franck Hussein ALVAREZ ROBLES se le designó como ASESOR(A) de Tesis al Mg. Ingrid Delia Dignarda Arteaga Espinoza, docente adscrito al Programa Académico de Ingeniería Civil, de la Facultad de Ingeniería, y;

Que, según Oficio N° 0175-2025-C-PAIC-FI-UDH, del Coordinador Académico quien informa que los JURADOS REVISORES del Trabajo de Investigación (Tesis) intitulado: "ANÁLISIS DE LA VARIACIÓN DEL VALOR DEL ÍNDICE DE REGULARIDAD INTERNACIONAL (IRI) DEL PAVIMENTO FLEXIBLE DE 1 KM DE LONGITUD MEDIANTE REDES NEURONALES Y EL PERFILÓMETRO LÁSER, 2025", presentado por el (la) Bach. Franck Hussein ALVAREZ ROBLES, integrado por los siguientes docentes: Mg. Ericka Selene Garcia Echevarria (Presidente), Mg. Yelen Lisseth Trujillo Ariza (Secretario) y en el caso de la Mg. Fátima Rosario Cecilio Reyes (Vocal) no aprobó el proyecto de Investigación por motivos que no tiene vínculo laboral, por lo que se declaran APTO por mayoría para ser ejecutado el Trabajo de Investigación (Tesis), y;

Estando a las atribuciones conferidas al Decano de la Facultad de Ingeniería y con cargo a dar cuenta en el próximo Consejo de Facultad.

SE RESUELVE:

Artículo Primero. - APROBAR, el Trabajo de Investigación (Tesis) y su ejecución intitulado: "ANÁLISIS DE LA VARIACIÓN DEL VALOR DEL ÍNDICE DE REGULARIDAD INTERNACIONAL (IRI) DEL PAVIMENTO FLEXIBLE DE 1 KM DE LONGITUD MEDIANTE REDES NEURONALES Y EL PERFILÓMETRO LÁSER, 2025", presentado por el (la) Bach. Franck Hussein ALVAREZ ROBLES, para optar el Título Profesional de Ingeniero(a) Civil, del Programa Académico de Ingeniería Civil, de la Universidad de Huánuco.

Artículo Segundo. - El Trabajo de Investigación (Tesis) deberá ejecutarse hasta un plazo máximo de 1 año de su Aprobación. En caso de incumplimiento podrá solicitar por única vez la ampliación del mismo (6 meses).

REGÍSTRESE, COMUNÍQUESE Y ARCHÍVESE



UNIVERSIDAD DE HUÁNUCO
FACULTAD DE INGENIERÍA
Ing. Ethel Dignarda Munzono Lozano
SECRETARIA DOCENTE



UNIVERSIDAD DE HUÁNUCO
DECANO
Mg. Rectoría Campos Ríos
DECANO DE LA FACULTAD DE INGENIERÍA

Distribución:

Fac. de Ingeniería - PAIC - Asesor - Exp. Gestionando - Interesado - Archivo.
BCR/EJML/rta.

Anexo 2: Resolución de nombramiento de Asesor

UNIVERSIDAD DE HUÁNUCO

Facultad de Ingeniería

RESOLUCIÓN Nº 1845-2024-D-FI-UDH

Huánuco, 28 de agosto de 2024

Visto, el Oficio N° 1269-2024-C-PAIC-FI-UDH presentado por el Coordinador del Programa Académico de Ingeniería Civil y el Expediente N° 501297-0000007425, del Bach. Franck Hussein ALVAREZ ROBLES, quien solicita Asesor de Tesis, para desarrollar el trabajo de investigación (Tesis).

CONSIDERANDO:

Que, de acuerdo a la Nueva Ley Universitaria 30220, Capítulo V, Art 45º inc. 45.2, es procedente su atención, y;

Que, según el Expediente N° 501297-0000007425, presentado por el (la) Bach. Franck Hussein ALVAREZ ROBLES, quien solicita Asesor de Tesis, para desarrollar su trabajo de investigación (Tesis), el mismo que propone a la Mg. Ingrid Delia Dignarda Arteaga Espinoza, como Asesor de Tesis, y;

Que, según lo dispuesto en el Capítulo II, Art. 27 y 28 del Reglamento General de Grados y Títulos de la Universidad de Huánuco vigente, es procedente atender lo solicitado, y;

Estando a Las atribuciones conferidas al Decano de la Facultad de Ingeniería y con cargo a dar cuenta en el próximo Consejo de Facultad.

SE RESUELVE:

Artículo Primero. - DESIGNAR, como Asesor de Tesis del Bach. Franck Hussein ALVAREZ ROBLES a la Mg. Ingrid Delia Dignarda Arteaga Espinoza, Docente del Programa Académico de Ingeniería Civil, Facultad de Ingeniería.

Artículo Segundo. - El interesado tendrá un plazo máximo de 6 meses para solicitar revisión del Trabajo de Investigación (Tesis). En todo caso deberá de solicitar nuevamente el trámite con el costo económico vigente.

REGÍSTRESE, COMUNÍQUESE Y ARCHÍVESE



UNIVERSIDAD DE HUÁNUCO
FACULTAD DE INGENIERÍA
Ing. Ethel Johana Manzano Lozano
SECRETARIA DOCENTE



UNIVERSIDAD DE HUÁNUCO
DECANO
Mg. Bertha Campos Ríos
DECANA DE LA FACULTAD DE INGENIERÍA

Distribución:

Fac. de Ingeniería - PAIC - Asesor - Mat. y Reg.Acad. - Interesado - Archivo.
BLCR/EJML/mto.

Anexo 03: matriz de consistencia

Tabla 11

Matriz de Consistencia

TÍTULO: "ANÁLISIS DE LA VARIACIÓN DEL VALOR DEL ÍNDICE DE REGULARIDAD INTERNACIONAL (IRI) DEL PAVIMENTO FLEXIBLE DE 1 KM DE LONGITUD MEDIANTE REDES NEURONALES Y EL PERFILÓMETRO LÁSER, 2025."

FORMULACIÓN DEL PROBLEMA	OBJETIVOS	HIPÓTESIS	TÉCNICAS E INSTRUMENTOS
Problema General: ¿Cuál es el análisis de la variación del valor del Índice de Regularidad Internacional (IRI) del pavimento flexible de 1 km de longitud, al ser analizado mediante un modelo de Redes Neuronales Artificiales en comparación con el valor obtenido a través del Perfilómetro Láser?	Objetivo general Analizar cómo varía el valor del Índice de Regularidad Internacional (IRI) del pavimento flexible de 1 km de longitud, a través de un modelo de Redes Neuronales Artificiales, en comparación con el valor obtenido utilizando el Perfilómetro Láser.	H1: La aplicación del modelo de Redes Neuronales Artificiales para analizar el pavimento flexible de 1 km de longitud, variará significativamente en comparación con el valor obtenido mediante el Perfilómetro Láser.	Se utilizarán técnicas de observación directa y la recolección de datos cuantitativos. Para la recolección de datos, se utilizarán dos instrumentos principales. Primero, se empleará el Perfilómetro Láser, Segundo, se utilizará un software de modelado de Redes Neuronales
Problemas Específicos: ¿Qué información será relevante y útil para incluir como entrada en el modelo neuronal, y cómo se puede asegurar su calidad y pertinencia? ¿Cómo se puede organizar la arquitectura del modelo neuronal para optimizar su desempeño y capacidad de aprendizaje en la tarea específica? ¿Cómo se establece la selección del método de aprendizaje más adecuado para el modelo neuronal, y cómo influirán en los resultados finales? ¿Cuál es la función de activación en el modelo neuronal para el diseño de un pavimento flexible?	Objetivos específicos Identificar qué información se utilizará como entrada en el modelo neuronal. Definir cómo está organizada la arquitectura del modelo neuronal. Establecer cuál será el método de aprendizaje más adecuado para el modelo neuronal, y cómo influirán en los resultados finales. Identificar qué función de activación se implementará en el modelo neuronal.	VARIABLES Variable Asociativa La aplicación del modelo de Redes Neuronales Artificiales para analizar el pavimento flexible de 1 km de longitud. Variable de Supervisión El valor del Índice de Regularidad Internacional (IRI) que variará en comparación con el valor obtenido mediante el Perfilómetro Láser.	
DISEÑO DE LA INVESTIGACIÓN	POBLACIÓN Y MUESTRA		

Enfoque Pertenece al enfoque cuantitativo. Alcance o Nivel correlacional. Diseño Pertenece a un diseño no experimental.	Población La población estará constituida por todas las vías urbanas de Huánuco con características similares a la Av. Universitaria en cuanto a tráfico y condiciones geotécnicas. Muestra La muestra incluirá específicamente la Av. Universitaria, en un tramo de 1 km de longitud, El cual se va a considerar aquel tramo que contenga todos los estudios básicos en cuanto a expediente técnico.
---	---

Anexo 04: mapa de ubicación

Figura 36

Ubicación de área de investigación



Anexo 05: instrumentos y registros

Tabla 12

Análisis IRI margen derecho

Start Distance (m)	Stop Distance (m)	Length (m)	Right - IRI (m/km)
0	0+000.00	20	3.95
20	0+020.00	20	26.13
40	0+040.00	20	7.44
60	0+060.00	20	4.24
80	0+080.00	20	3.11
100	0+100.00	20	3.86
120	0+120.00	20	2.74
140	0+140.00	20	9.09
160	0+160.00	20	23.74
180	0+180.00	20	4.29
200	0+200.00	20	2.88
220	0+220.00	20	3.47
240	0+240.00	20	2.65
260	0+260.00	20	3.75
280	0+280.00	20	18.72
300	0+300.00	20	9.93
320	0+320.00	20	3.39
340	0+340.00	20	3.80
360	0+360.00	20	3.62
380	0+380.00	20	3.14
400	0+400.00	20	3.39
420	0+420.00	20	22.26
440	0+440.00	20	5.66
460	0+460.00	20	2.76
480	0+480.00	20	3.39
500	0+500.00	20	2.98
520	0+520.00	20	2.50
540	0+540.00	20	3.19
560	0+560.00	20	3.12
580	0+580.00	20	3.60
600	0+600.00	20	3.42
620	0+620.00	20	3.46
640	0+640.00	20	3.13
660	0+660.00	20	3.42
680	0+680.00	20	3.15

700	0+700.00	20	19.69
720	0+720.00	20	5.37
740	0+740.00	20	2.89
760	0+760.00	20	5.99
780	0+780.00	20	4.30
800	0+800.00	20	3.48
820	0+820.00	20	3.36
840	0+840.00	20	25.16
860	0+860.00	20	5.87
880	0+880.00	20	4.72
900	0+900.00	20	3.64
920	0+920.00	20	3.35
940	0+940.00	20	3.65
960	0+960.00	20	2.68
980	0+980.00	20	3.06
1000	1+000.00	7.5	4.01

Tabla 13

Análisis IRI margen Izquierdo

Start Distance (m)	Stop Distance (m)	Length (m)	Left - IRI (m/km)
0	0+020.00	20	3.06
20	0+040.00	20	25.91
40	0+060.00	20	7.61
60	0+080.00	20	4.02
80	0+100.00	20	3.51
100	0+120.00	20	3.08
120	0+140.00	20	3.54
140	0+160.00	20	9.19
160	0+180.00	20	24.22
180	0+200.00	20	3.82
200	0+220.00	20	2.98
220	0+240.00	20	3.44
240	0+260.00	20	3.14
260	0+280.00	20	3.15
280	0+300.00	20	18.09
300	0+320.00	20	9.88
320	0+340.00	20	3.28
340	0+360.00	20	3.19
360	0+380.00	20	3.66
380	0+400.00	20	3.08
400	0+420.00	20	3.17
420	0+440.00	20	22.61

440	0+460.00	20	6.07
460	0+480.00	20	3.87
480	0+500.00	20	2.57
500	0+520.00	20	3.09
520	0+540.00	20	3.12
540	0+560.00	20	2.92
560	0+580.00	20	3.06
580	0+600.00	20	3.98
600	0+620.00	20	3.12
620	0+640.00	20	3.27
640	0+660.00	20	4.00
660	0+680.00	20	3.44
680	0+700.00	20	3.91
700	0+720.00	20	19.87
720	0+740.00	20	5.24
740	0+760.00	20	3.92
760	0+780.00	20	5.96
780	0+800.00	20	3.81
800	0+820.00	20	4.08
820	0+840.00	20	4.35
840	0+860.00	20	24.79
860	0+880.00	20	5.87
880	0+900.00	20	3.35
900	0+920.00	20	3.87
920	0+940.00	20	2.71
940	0+960.00	20	3.11
960	0+980.00	20	3.29
980	1+000.00	20	3.35
1000	1+007.50	7.5	2.88

Tabla 14

Matriz PSI margen derecho

CARACTERIZACIÓN PSI CARRIL DERECHO																					
Progre siva	Pie l de cocodr ilo	Exu dación	Agrie tamiento en bloqu e	Abult amiento / Hundi miento	Corr ugación	De pre sión	Grie tas de borde	Grie tas de reflexi ón de juntas	De snivel Carril / Berma	Grie tas Lon gitudinal y trans versal	Pa rqueo	Puli miento de agra vados	Hue cos	Cr uce de vía fé rrea	Ahue llamiento	Despl azamiento	Grie ta par abólica	Hinc amiento	Despr endimiento	De sgaste	PR OM EDIO
0+0 00.00	0.0 0%	0.0 0%	0.00 %	0.00 %	0.00 %	0.0 0%	0.00 %	0.0 0%	0.0 0%	0.00 %	0.0 0%	0.0 0%	0.00 %	0.00 %	0.00 %	0.00%	0.0 0%	0.00 %	0.00%	0.0 0%	#iDI V/O!
0+0 20.00	85.09 %	92.91 %	78.2 9%	34.7 7%	0.00 %	87.90 %	74.7 8%	0.0 0%	0.0 0%	0.00 %	0.0 0%	0.0 0%	0.00 %	0.00 %	0.00 %	0.00%	0.0 0%	0.00 %	0.00%	91.44 %	79.9 1%
0+0 40.00	47.19 %	40.95 %	20.8 1%	0.00 %	26.8 5%	0.0 0%	0.00 %	0.0 0%	48.67 %	0.00 %	0.0 0%	0.0 0%	0.00 %	0.00 %	0.00 %	0.00%	0.0 0%	0.00 %	0.00%	0.0 0%	38.4 5%

91

0+680.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
0+700.00	0.00%	0.00%	0.00%	79.84%	48.98%	76.02%	21.83%	0.00%	42.23%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	77.92%	0.00%	0.00%	0.00%	0.00%	51.35%	56.88%
0+720.00	29.54%	49.41%	28.59%	23.51%	33.71%	27.86%	0.00%	0.00%	32.22%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	32.97%	0.00%	0.00%	0.00%	0.00%	23.51%	31.26%	
0+740.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
0+760.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
0+780.00	26.54%	0.00%	39.33%	27.86%	47.84%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	44.44%	35.27%	0.00%	0.00%	0.00%	0.00%	47.26%	36.18%
0+800.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
0+820.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
0+840.00	68.49%	43.19%	25.11%	83.91%	58.51%	40.91%	0.00%	0.00%	78.73%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	79.63%	98.27%	0.00%	0.00%	0.00%	0.00%	61.24%	
0+860.00	42.90%	0.00%	43.80%	44.70%	23.48%	0.00%	0.00%	0.00%	48.47%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	29.45%	24.19%	0.00%	0.00%	0.00%	0.00%	35.71%	
0+880.00	0.00%	35.34%	40.78%	37.65%	46.14%	46.71%	0.00%	0.00%	34.51%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	22.89%	0.00%	0.00%	0.00%	0.00%	47.26%	39.22%
0+900.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
0+920.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
0+940.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
0+960.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
0+980.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!	
1+000.00	35.50%	48.11%	0.00%	0.00%	39.82%	0.00%	0.00%	0.00%	25.15%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	20.59%	0.00%	0.00%	0.00%	0.00%	33.83%	

Tabla 15

Matriz PSI margen izquierdo

CARACTERIZACIÓN PSI CARRIL IZQUIERDO																					
Progre siva	Pie l de coc odr ilo	Exu daci ón	Agrie tamie nto en bloqu e	Abult amie nto / Hun dimie nto	Corr uga ción	De pre sió n	Gri et as de bord e	Gri etas de refl exi ón de jun tas	De sni vel Car ril / Be rm a	Grie tas Lon gitu dinal y tran sver sal	Pa rch eo	Puli me nto de agra gados	Hu ecos	Cr uc e de ví a fé rr ea	Ahue llami ento	Despl azami ento	Gri eta par abó lica	Hinc hami ento	Despr endimi ento	De sga ste	PR OM ED IO
0+000.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!
0+020.00	37.54%	72.95%	34.55%	80.45%	0.00%	84.68%	46.24%	0.00%	47.93%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	51.33%	61.18%
0+040.00	0.00%	0.00%	42.11%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	39.52%	0.00%	0.00%	0.00%	0.00%	40.81%
0+060.00	44.26%	34.61%	0.00%	47.32%	43.92%	0.00%	0.00%	0.00%	41.40%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	44.34%	0.00%	0.00%	0.00%	0.00%	43.55%
0+080.00	0.00%	28.52%	0.00%	33.43%	27.77%	25.51%	20.2%	0.00%	22.54%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	48.24%	0.00%	0.00%	0.00%	48.93%	31.87%
0+100.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!
0+120.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!
0+140.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#iDI V/O!

0+1 60.00	27.41 0.0%	0.0%	29.2 3%	37.3 2%	27.1 5%	0.0%	49.1 2%	0.0%	39.3 7%	0.00 %	0.0%	0.0%	32.3 8%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	34.0 9%	34.5 1%
0+1 80.00	33.92 %	63.25 %	30.7 2%	45.6 3%	61.9 2%	98.63 %	45.1 0%	0.0%	79.45 %	0.00 %	0.0%	0.0%	59.2 5%	0.00 %	84.07 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	60.1 9%
0+2 00.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+2 20.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+2 40.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+2 60.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+2 80.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+3 00.00	38.99 %	29.10 %	0.00 %	37.5 3%	36.2 4%	0.0%	0.00 %	0.0%	31.21 %	0.00 %	0.0%	0.0%	42.8 %	0.00 %	26.65 %	0.00 %	0.00 %	0.00 %	0.00 %	41.5 %	35.4 4%
0+3 20.00	20.06 %	0.0%	0.00 %	24.6 1%	0.00 %	0.0%	0.00 %	0.0%	48.23 %	0.00 %	0.0%	0.0%	27.8 2%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	30.1 8%
0+3 40.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+3 60.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+3 80.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+4 00.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+4 20.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+4 40.00	71.28 %	24.44 %	81.2 2%	44.8 2%	77.9 3%	65.09 %	91.6 5%	0.0%	58.62 %	0.00 %	0.0%	0.0%	51.6 0%	0.00 %	33.13 %	0.00 %	0.00 %	0.00 %	0.00 %	57.2 2%	59.7 3%
0+4 60.00	0.0%	0.0%	23.6 4%	0.00 %	36.2 5%	0.0%	46.1 8%	0.0%	49.73 %	0.00 %	0.0%	0.0%	32.6 8%	0.00 %	42.27 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	38.4 6%
0+4 80.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+5 00.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+5 20.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+5 40.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+5 60.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+5 80.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+6 00.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+6 20.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+6 40.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+6 60.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+6 80.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+7 00.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!
0+7 20.00	62.83 %	0.0%	0.00 %	0.00 %	51.1 6%	0.0%	38.8 2%	0.0%	54.52 %	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	91.1 %	59.6 8%
0+7 40.00	0.0%	0.0%	33.0 5%	0.00 %	0.00 %	21.4 0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	26.83 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	27.0 9%
0+7 60.00	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.0%	0.0%	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.00 %	0.0%	#DI V/O!

0+780.00	20.51%	31.72%	0.00%	0.00%	23.59%	21.38%	26.06%	0.00%	0.00%	0.00%	0.00%	0.00%	23.74%	0.00%	0.00%	0.00%	0.00%	0.00%	33.86%	25.84%
0+800.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#jDI V/O!
0+820.00	0.00%	24.46%	21.36%	0.00%	35.70%	0.00%	38.57%	0.00%	41.94%	0.00%	0.00%	0.00%	0.00%	0.00%	49.77%	0.00%	0.00%	0.00%	33.47%	35.04%
0+840.00	0.00%	32.25%	0.00%	32.56%	0.00%	40.70%	26.03%	0.00%	0.00%	0.00%	0.00%	0.00%	25.27%	0.00%	23.41%	0.00%	0.00%	0.00%	41.02%	31.61%
0+860.00	76.98%	47.99%	25.96%	64.36%	83.94%	51.57%	97.50%	0.00%	0.00%	0.00%	0.00%	0.00%	24.00%	0.00%	84.75%	0.00%	0.00%	0.00%	0.00%	61.90%
0+880.00	0.00%	0.00%	45.82%	0.00%	34.74%	38.95%	42.13%	0.00%	25.16%	0.00%	0.00%	0.00%	48.58%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	39.23%
0+900.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#jDI V/O!
0+920.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#jDI V/O!
0+940.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#jDI V/O!
0+960.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#jDI V/O!
0+980.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#jDI V/O!
1+000.00	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	#jDI V/O!

Tabla 16

Valores de variables ingresadas para entrenamiento – Carril derecho

Estimación promedio de variables					
Progresiva	V1	V2	V3	V4	V5
0+000.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+020.00	81.69%	46.45%	40.89%	61.85%	74.78%
0+040.00	34.00%	33.90%	0.00%	31.64%	0.00%
0+060.00	0.00%	0.00%	10.78%	7.48%	27.64%
0+080.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+100.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+120.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+140.00	0.00%	10.79%	15.43%	23.48%	0.00%
0+160.00	51.55%	42.24%	54.91%	74.03%	0.00%
0+180.00	15.07%	0.00%	6.90%	20.10%	25.09%
0+200.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+220.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+240.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+260.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+280.00	32.13%	67.49%	58.09%	37.87%	0.00%
0+300.00	22.88%	11.16%	16.48%	25.96%	39.39%
0+320.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+340.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+360.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+380.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+400.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+420.00	17.83%	40.39%	10.74%	46.15%	75.45%
0+440.00	36.83%	0.00%	25.58%	11.96%	0.00%
0+460.00	0.00%	0.00%	0.00%	0.00%	0.00%

0+480.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+500.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+520.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+540.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+560.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+580.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+600.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+620.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+640.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+660.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+680.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+700.00	0.00%	24.49%	77.93%	31.20%	21.83%
0+720.00	29.06%	41.56%	17.12%	29.57%	0.00%
0+740.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+760.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+780.00	32.93%	23.92%	21.04%	30.57%	20.90%
0+800.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+820.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+840.00	46.80%	50.85%	74.36%	52.79%	35.64%
0+860.00	43.35%	11.74%	22.96%	25.97%	28.71%
0+880.00	20.39%	40.74%	35.75%	27.26%	41.72%
0+900.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+920.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+940.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+960.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+980.00	0.00%	0.00%	0.00%	0.00%	0.00%
1+000.00	17.75%	43.96%	6.86%	8.38%	0.00%

Tabla 17

Valores de variables ingresadas para comprobación – Carril izquierdo

Estimación promedio de variables					
Progresiva	V1	V2	V3	V4	V5
0+000.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+020.00	36.04%	36.48%	55.04%	64.74%	46.24%
0+040.00	21.05%	0.00%	13.17%	0.00%	0.00%
0+060.00	22.13%	39.27%	30.55%	30.13%	0.00%
0+080.00	0.00%	28.15%	35.73%	23.82%	20.02%
0+100.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+120.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+140.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+160.00	28.32%	13.58%	12.44%	35.28%	49.12%
0+180.00	32.32%	62.59%	76.11%	46.23%	45.10%
0+200.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+220.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+240.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+260.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+280.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+300.00	19.49%	32.67%	21.39%	38.33%	0.00%
0+320.00	10.03%	0.00%	8.20%	25.35%	0.00%
0+340.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+360.00	0.00%	0.00%	0.00%	0.00%	0.00%

0+380.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+400.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+420.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+440.00	76.25%	51.18%	47.68%	55.81%	91.65%
0+460.00	11.82%	18.12%	14.09%	27.47%	46.18%
0+480.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+500.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+520.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+540.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+560.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+580.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+600.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+620.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+640.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+660.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+680.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+700.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+720.00	31.42%	25.58%	0.00%	48.54%	38.82%
0+740.00	16.53%	0.00%	16.08%	0.00%	0.00%
0+760.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+780.00	10.25%	27.65%	7.13%	19.20%	26.06%
0+800.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+820.00	10.68%	30.08%	16.59%	25.14%	38.57%
0+840.00	0.00%	16.13%	32.22%	22.10%	26.03%
0+860.00	51.47%	65.96%	66.89%	8.00%	97.50%
0+880.00	22.91%	17.37%	12.98%	24.58%	42.13%
0+900.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+920.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+940.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+960.00	0.00%	0.00%	0.00%	0.00%	0.00%
0+980.00	0.00%	0.00%	0.00%	0.00%	0.00%
1+000.00	0.00%	0.00%	0.00%	0.00%	0.00%

Figura 37

Código de programación de red neuronal

21/3/25, 18:36

Copia de MODELO DE RED NEURONAL IRI - Colab

```
import tensorflow as tf
import numpy as np
!pip install visualkeras
import visualkeras
from PIL import ImageFont

Collecting visualkeras
  Downloading visualkeras-0.1.4-py3-none-any.whl.metadata (11 kB)
Requirement already satisfied: pillow>=6.2.0 in /usr/local/lib/python3.11/dist-packages (from visualkeras) (11.1.0)
Requirement already satisfied: numpy>=1.18.1 in /usr/local/lib/python3.11/dist-packages (from visualkeras) (2.0.2)
Collecting aggdraw>=1.3.11 (from visualkeras)
  Downloading aggdraw-1.3.19-cp311-cp311-manylinux_2_17_x86_64.manylinux2014_x86_64.whl.metadata (655 bytes)
  Downloading visualkeras-0.1.4-py3-none-any.whl (17 kB)
  Downloading aggdraw-1.3.19-cp311-cp311-manylinux_2_17_x86_64.manylinux2014_x86_64.whl (997 kB)
    997.4/997.4 kB 13.6 MB/s eta 0:00:00
Installing collected packages: aggdraw, visualkeras
Successfully installed aggdraw-1.3.19 visualkeras-0.1.4

V1 = np.array([0, 0.816899121, 0.340826084, 0, 0, 0, 0, 0.515548483, 0.150655945, 0, 0, 0, 0, 0.321340811, 0.228772153, 0, 0, 0, 0, 0.107934464, 0.422389837, 0, 0, 0, 0, 0.674930495, 0.111612142, 0, 0, 0, 0, 0.408915971, 0, 0.187825852, 0, 0, 0, 0.154291765, 0.549127179, 0.06897492, 0, 0, 0, 0.580869671, 0.164789, 0, 0.618520819, 0.31636966, 0.074833938, 0, 0, 0, 0.234751459, 0.740321435, 0.200988204, 0, 0, 0, 0.378705058, 0.25957, 0.74775416, 0, 0.276370088, 0, 0, 0, 0, 0.250948136, 0, 0, 0, 0, 0.393859712, 0, 0, 0, 0, 0.75451157, 0, 0, 0, 0, 0.395, 26.13, 7.44, 4.24, 3.11, 3.86, 2.74, 9.09, 23.74, 4.29, 2.88, 3.47, 2.65, 3.75, 18.72, 9.93, 3.39, 3.80, 3.62, 3.11])
IRI = np.array([3.95, 26.13, 7.44, 4.24, 3.11, 3.86, 2.74, 9.09, 23.74, 4.29, 2.88, 3.47, 2.65, 3.75, 18.72, 9.93, 3.39, 3.80, 3.62, 3.11])

min_length = min(len(V1), len(V2), len(V3), len(V4), len(V5))
V1 = V1[:min_length]
V2 = V2[:min_length]
V3 = V3[:min_length]
V4 = V4[:min_length]
V5 = V5[:min_length]
X = np.stack([V1, V2, V3, V4, V5], axis=1)
X = X.reshape(-1, 5)

oculta1 = tf.keras.layers.Dense(units=10, input_shape=[5])
oculta2 = tf.keras.layers.Dense(units=10)
oculta3 = tf.keras.layers.Dense(units=10)
salida = tf.keras.layers.Dense(units=1)
modelo = tf.keras.Sequential([oculta1, oculta2, oculta3, salida])

/usr/local/lib/python3.11/dist-packages/keras/src/layers/core/dense.py:87: UserWarning: Do not pass an `input_shape`/`input_dim` arg to
super().__init__(activity_regularizer=activity_regularizer, **kwargs)

modelo.compile(
    optimizer=tf.keras.optimizers.Adam(0.1),
    loss='mean_squared_error'
)

print("Comenzando entrenamiento...")
historial = modelo.fit(X, IRI, epochs=1000, verbose=False)
print("Modelo entrenado!")

Comenzando entrenamiento...
Modelo entrenado!

import matplotlib.pyplot as plt


# Generar la gráfica de MSE
plt.xlabel("# Época")
plt.ylabel("Magnitud de Pérdida (MSE)")
plt.plot(historial.history["loss"]) # 'loss' contiene el MSE por época
plt.title("Gráfica de Error Cuadrático Medio durante el Entrenamiento")
plt.show()
```

https://colab.research.google.com/drive/13g6aaOwirdW_BYaUwcAM-YFdBjFe5JK#printMode=true

1/5



Gráfica de Error Cuadrático Medio durante el Entrenamiento



```
print(X)
```



```
[[0. 0. 0. 0. ]
 [0.81689912 0.46454874 0. 0.61852802 0.74775416]
 [0.34882688 0.33988339 0.48891597 0.31636966 0. ]
 [0. 0. 0. 0.07483394 0.27637889]
 [0. 0. 0.10782585 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0.18793446 0. 0.23475145 0. ]
 [0.51554848 0.42238984 0.15429176 0.74832144 0. ]
 [0.15865595 0. 0.54912718 0.2809882 0.25094814]
 [0. 0. 0.06897492 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0.32134881 0.0749385 0. 0.37878586 0. ]
 [0.22877215 0.11161214 0.58886967 0.25957519 0.39385971]
 [0. 0. 0.164789 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0.17829635 0.48391523 0. 0.46158376 0.75451157]
 [0.36829571 0. 0.10735798 0.11964398 0. ]
 [0. 0. 0.25578842 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0.24491914 0. 0.31195266 0.21833553]
 [0.29863651 0.41559738 0.77926972 0.29566758 0. ]
 [0. 0. 0.17121485 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0.32934917 0.23918881 0. 0.30567225 0.28896638]
 [0. 0. 0.21841886 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0.46798278 0.58847843 0. 0.52786617 0.35639112]
 [0.43353797 0.11748586 0.7435988 0.25973473 0.28713189]
 [0.28398656 0.48736721 0.22961658 0.27256772 0.41716182]
 [0. 0. 0.35751367 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0. 0. 0. 0. 0. ]
 [0.17751857 0.43963172 0. 0.8838247 0. ]]
```

```
import numpy as np
import matplotlib.pyplot as plt
```

```
# Calcular el coeficiente de correlación
coeficiente_correlacion = np.corrcoef(IRI, modelo.predict(X).flatten())[0, 1]
```

https://colab.research.google.com/drive/13g8aaOwirdW_BYaUwcAM-YFdEbjFe5JK#printMode=true

2/5

```

# Obtener detalles de la red neuronal
num_variables = X.shape[1] # Número de variables de entrada
num_neuronas = modelo.layers[0].units + modelo.layers[1].units + modelo.layers[2].units # Total de neuronas en capas ocultas
num_epocas = len(historial.history['loss']) # Número de épocas de entrenamiento
num_capas = len(modelo.layers) - 1 # Número de capas en el modelo

# Generar la gráfica de dispersión
plt.scatter(IRI, modelo.predict(X))
plt.xlabel("Valores Reales de IRI")
plt.ylabel("Valores Predichos de IRI")
plt.title("Gráfica de Entrenamiento vs. Datos de Entrenamiento")
plt.plot([IRI.min(), IRI.max()], [IRI.min(), IRI.max()], 'k--', lw=2) # Línea de referencia (y=x)


# Agregar coeficiente de correlación y detalles de la red a la gráfica
texto_detalle = f'Coeficiente de Correlación: {coeficiente_correlacion:.2f}\n' \
f'Variables: {num_variables}\n' \
f'Capas: {num_capas}\n' \
f'Neuronas: {num_neuronas}\n' \
f'Épocas: {num_epocas}'

# Propiedades del cuadro de texto
propiedades_cuadro = dict(boxstyle='round', facecolor='wheat', alpha=0.5)

# Colocar el cuadro de texto en la esquina superior izquierda
plt.text(0.05, 0.95, texto_detalle, transform=plt.gca().transAxes, fontsize=8,
verticalalignment='top', bbox=propiedades_cuadro)

plt.show()

```



```

VR1 = np.array([0, 0.360418371, 0.210535057, 0.221306335, 0, 0, 0, 0.283224449, 0.323186582, 0, 0, 0, 0, 0.194925997, 0.1003225, 0,
VR2 = np.array([0, 0.364764886, 0, 0.392650059, 0.281454468, 0, 0, 0, 0.13576154, 0.625887067, 0, 0, 0, 0.326721463, 0, 0, 0, 0,
VR3 = np.array([0, 0.550431672, 0.131734796, 0.305519007, 0.357300923, 0, 0, 0, 0.124394564, 0.761085507, 0, 0, 0, 0, 0.213929506, 0.0
VR4 = np.array([0, 0.647300486, 0, 0.301339170, 0.238241511, 0, 0, 0, 0.352808791, 0.462316253, 0, 0, 0, 0, 0.383296562, 0.253508313,
VR5 = np.array([0, 0.462449527, 0, 0, 0.200171752, 0, 0, 0, 0.491165228, 0.451013889, 0, 0, 0, 0, 0, 0, 0, 0.91647036, 0.4
IRIR = np.array([3.057479, 25.91078, 7.61269, 4.020916, 3.510472, 3.081009, 3.544457, 9.185957, 24.22303, 3.817044, 2.982999, 3.444321, 3

```

```

min_length = min(len(VR1), len(VR2), len(VR3), len(VR4), len(VR5))
VR1 = VR1[:min_length]
VR2 = VR2[:min_length]
VR3 = VR3[:min_length]
VR4 = VR4[:min_length]
VR5 = VR5[:min_length]
X2 = np.stack([VR1, VR2, VR3, VR4, VR5], axis=1)
X2 = X2.reshape(-1, 5)

print("Hagamos una predicción!")
resultado = modelo.predict([X2])
print("El resultado es: ")
print(resultado)
derecha = modelo.predict(X)
print(derecha)

```

```

Hagamos una predicción!
2/2 ----- 0s 58ms/step
El resultado es:
[[ 3.2845984]
 [20.188498 ]
 [ 1.1253538]
 [ 9.72875 ]
 [ 9.116979 ]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [14.382184 ]
 [12.65918 ]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [13.272934 ]
 [10.428181 ]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [17.614838 ]
 [12.441849 ]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [19.235794 ]
 [ 1.124863 ]
 [ 3.2845984]
 [ 9.624811 ]
 [ 3.2845984]
 [11.283632 ]
 [ 9.017426 ]
 [ 1.9218888]
 [10.8451 ]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]
 [ 3.2845984]]
2/2 ----- 0s 28ms/step
/usr/local/lib/python3.11/dist-packages/keras/src/models/functional.py:237: UserWarning: The structure of `inputs` doesn't match
Expected: keras_tensor

```

```

import numpy as np
import matplotlib.pyplot as plt

```

```

# Calcular el coeficiente de correlación
coeficiente_correlacion = np.corrcoef(IRIR, modelo.predict(X2).flatten())[0, 1]

# Obtener detalles de la red neuronal
num_variables = X2.shape[1] # Número de variables de entrada
num_neuronas = modelo.layers[0].units + modelo.layers[1].units + modelo.layers[2].units # Total de neuronas en capas ocultas
num_epocas = len(historical.history['loss']) # Número de épocas de entrenamiento
num_capas = len(modelo.layers) - 1 # Número de capas en el modelo

# Generar la gráfica de dispersión
plt.scatter(IRIR, modelo.predict(X2))
plt.xlabel("Valores Reales de IRI carril izquierdo")
plt.ylabel("Valores Predichos de IRI")
plt.title("IRI carril izquierdo vs. Datos predichos")
plt.plot([IRIR.min(), IRIR.max()], [IRIR.min(), IRIR.max()], 'k--', lw=2) # Línea de referencia (y=x)

# Agregar coeficiente de correlación y detalles de la red a la gráfica
texto_detalle = f'Coeficiente de Correlación: {coeficiente_correlacion:.2f}\n' \
                f'Variables: {num_variables}\n' \
                f'Capas: {num_capas}\n' \
                f'Neuronas: {num_neuronas}\n' \
                f'Épocas: {num_epocas}'

# Propiedades del cuadro de texto

```

21/3/25, 18:36

Copia de MODELO DE RED NEURONAL IRI - Colab

```
propiedades_cuadro = dict(boxstyle='round', facecolor='wheat', alpha=0.5)
```

```
# Colocar el cuadro de texto en la esquina superior izquierda
plt.text(0.05, 0.95, texto_detalle, transform=plt.gca().transAxes, fontsize=8,
        verticalalignment='top', bbox=propiedades_cuadro)
```

```
plt.show()
```

```
2/2 0s 22ms/step
2/2 0s 23ms/step
```




Tabla 18

Análisis de correlación carril derecho

ANÁLISIS DE CORRELACIÓN EN IRI CARRIL DERECHO					
PROGRESIVA	IRI	MODELO 1	MODELO 2	MODELO 3	MODELO 4
0+020.00	3.95	3.80	3.28	3.56	3.28
0+040.00	26.13	23.80	22.51	25.13	23.70
0+060.00	7.44	9.79	8.75	10.18	9.20
0+080.00	4.24	7.35	6.83	7.37	7.00
0+100.00	3.11	2.94	2.41	2.67	2.41
0+120.00	3.86	3.80	3.28	3.56	3.28
0+140.00	2.74	3.80	3.28	3.56	3.28
0+160.00	9.09	11.74	11.04	12.10	11.25
0+180.00	23.74	25.23	23.87	26.65	24.69
0+200.00	4.29	6.39	5.63	6.45	5.89
0+220.00	2.88	3.25	2.72	2.99	2.72
0+240.00	3.47	3.80	3.28	3.56	3.28
0+260.00	2.65	3.80	3.28	3.56	3.28
0+280.00	3.75	3.80	3.28	3.56	3.28
0+300.00	18.72	15.49	14.35	16.34	15.06
0+320.00	9.93	8.35	7.50	8.61	7.94
0+340.00	3.39	2.49	1.95	2.20	1.94
0+360.00	3.80	3.80	3.28	3.56	3.28
0+380.00	3.62	3.80	3.28	3.56	3.28
0+400.00	3.14	3.80	3.28	3.56	3.28
0+420.00	3.39	3.80	3.28	3.56	3.28
0+440.00	22.26	21.57	20.65	22.77	21.56
0+460.00	5.66	5.19	4.44	5.04	4.60
0+480.00	2.76	1.77	1.21	1.44	1.20
0+500.00	3.39	3.80	3.28	3.56	3.28
0+520.00	2.98	3.80	3.28	3.56	3.28
0+540.00	2.50	3.80	3.28	3.56	3.28
0+560.00	3.19	3.80	3.28	3.56	3.28

0+580.00	3.12	3.80	3.28	3.56	3.28
0+600.00	3.60	3.80	3.28	3.56	3.28
0+620.00	3.42	3.80	3.28	3.56	3.28
0+640.00	3.46	3.80	3.28	3.56	3.28
0+660.00	3.13	3.80	3.28	3.56	3.28
0+680.00	3.42	3.80	3.28	3.56	3.28
0+700.00	3.15	3.80	3.28	3.56	3.28
0+720.00	19.69	15.26	14.49	15.94	14.93
0+740.00	5.37	6.45	5.35	6.74	5.81
0+760.00	2.89	2.44	1.89	2.14	1.89
0+780.00	5.99	3.80	3.28	3.56	3.28
0+800.00	4.30	13.44	12.54	13.96	13.05
0+820.00	3.48	2.13	1.58	1.82	1.57
0+840.00	3.36	3.80	3.28	3.56	3.28
0+860.00	25.16	20.99	19.82	22.15	20.72
0+880.00	5.87	5.69	4.71	5.78	5.15
0+900.00	4.72	12.03	11.13	12.60	11.77
0+920.00	3.64	0.96	0.38	0.60	0.37
0+940.00	3.35	3.80	3.28	3.56	3.28
0+960.00	3.65	3.80	3.28	3.56	3.28
0+980.00	2.68	3.80	3.28	3.56	3.28
1+000.00	3.06	3.80	3.28	3.56	3.28
1+007.50	4.01	6.12	5.31	6.22	5.66
Coefficiente de correlación	0.936155	0.936076	0.936045	0.936089	
Determinación (R^2)	0.876386	0.876238	0.876180	0.876263	

Tabla 19

Análisis correlacional carril izquierdo

ANÁLISIS DE CORRELACIÓN EN IRI CARRIL IZQUIERDO					
PROGRESIVA	IRI	MODELO 1	MODELO 2	MODELO 3	MODELO 4
0+020.00	3.06	3.80	3.28	3.56	3.28
0+040.00	25.91	21.41	20.19	22.67	21.08
0+060.00	7.61	1.75	1.13	1.38	1.17
0+080.00	4.02	10.72	9.73	11.19	10.18
0+100.00	3.51	9.92	9.12	10.32	9.51
0+120.00	3.08	3.80	3.28	3.56	3.28
0+140.00	3.54	3.80	3.28	3.56	3.28
0+160.00	9.19	3.80	3.28	3.56	3.28
0+180.00	24.22	15.23	14.38	15.87	14.97
0+200.00	3.82	13.89	12.66	14.81	13.56
0+220.00	2.98	3.80	3.28	3.56	3.28
0+240.00	3.44	3.80	3.28	3.56	3.28
0+260.00	3.14	3.80	3.28	3.56	3.28
0+280.00	3.15	3.80	3.28	3.56	3.28
0+300.00	18.09	3.80	3.28	3.56	3.28
0+320.00	9.88	14.26	13.27	14.93	13.74
0+340.00	3.28	11.15	10.43	11.43	10.61
0+360.00	3.19	3.80	3.28	3.56	3.28
0+380.00	3.66	3.80	3.28	3.56	3.28
0+400.00	3.08	3.80	3.28	3.56	3.28
0+420.00	3.17	3.80	3.28	3.56	3.28
0+440.00	22.61	3.80	3.28	3.56	3.28

0+460.00	6.07	18.93	17.61	20.06	18.85
0+480.00	3.87	13.20	12.44	13.74	12.95
0+500.00	2.57	3.80	3.28	3.56	3.28
0+520.00	3.09	3.80	3.28	3.56	3.28
0+540.00	3.12	3.80	3.28	3.56	3.28
0+560.00	2.92	3.80	3.28	3.56	3.28
0+580.00	3.06	3.80	3.28	3.56	3.28
0+600.00	3.98	3.80	3.28	3.56	3.28
0+620.00	3.12	3.80	3.28	3.56	3.28
0+640.00	3.27	3.80	3.28	3.56	3.28
0+660.00	4.00	3.80	3.28	3.56	3.28
0+680.00	3.44	3.80	3.28	3.56	3.28
0+700.00	3.91	3.80	3.28	3.56	3.28
0+720.00	19.87	3.80	3.28	3.56	3.28
0+740.00	5.24	20.22	19.24	21.22	19.94
0+760.00	3.92	1.73	1.12	1.37	1.16
0+780.00	5.96	3.80	3.28	3.56	3.28
0+800.00	3.81	10.38	9.62	10.74	10.04
0+820.00	4.08	3.80	3.28	3.56	3.28
0+840.00	4.35	12.08	11.28	12.60	11.81
0+860.00	24.79	9.75	9.02	10.08	9.35
0+880.00	5.87	2.92	1.92	3.09	2.90
0+900.00	3.35	11.63	10.85	12.04	11.34
0+920.00	3.87	3.80	3.28	3.56	3.28
0+940.00	2.71	3.80	3.28	3.56	3.28
0+960.00	3.11	3.80	3.28	3.56	3.28
0+980.00	3.29	3.80	3.28	3.56	3.28
1+000.00	3.35	3.80	3.28	3.56	3.28
1+007.50	2.88	3.80	3.28	3.56	3.28
Coefficiente de correlación	0.343161	0.344191	0.342432	0.342469	
Determinación (R^2)	0.117759	0.118467	0.117259	0.117285	

ANEXO: PANEL FOTOGRAFICO



Foto panorámica longitudinal del eje vial



Foto panorámica longitudinal del eje vial



Foto de baches en el tramo del área en estudio.



Foto de baches en el tramo del área en estudio.



Foto de baches en el tramo del área en estudio.



Foto de área rehabilitada