

Pasantía de investigación: “Apoyo en la instrumentación de una viga e implementación de una Red Neuronal con aprendizaje supervisado para estimar temperatura en el concreto dentro del proyecto de investigación VIE-UIS No2823”

Luis Dario Villamil Contreras

Trabajo de Grado para Optar al Título de Ingeniero Civil

Director

Oscar Javier Begambre Carrillo

Doctorado en Ingeniería Civil – Estructuras

Codirector

José Miguel Benjumea Royero

Ph. D. in Civil and Environmental Engineering

Universidad Industrial de Santander

Facultad de Físicomecánica

Escuela de Ingeniería Civil

Programa Académico

Bucaramanga

2023

Dedicatoria

Le dedico el resultado de este trabajo a mi familia. Principalmente, a mis padres que me brindaron su amor, apoyo y enseñanza. Gracias por sus palabras siempre me han inspirado a seguir adelante, su ejemplo me ha mostrado que todo es posible con esfuerzo y dedicación. Por ser mis mejores guías, estar siempre ahí para mí, y por ayudarme a convertirme en la persona que soy hoy.

A mis amigos, compañeros de vida y cómplices de mis sueños. Por su apoyo y aliento me ayudaron a superar momentos difíciles y a culminar esta etapa con éxito.

Agradecimientos

Agradezco a Dios por bendecirme en la vida, y permitirme alcanzar este sueño. Su guía y apoyo me acompañó en todo momento.

A mis padres gracias por ser los principales promotores de mis sueños. Confiaron y creyeron en mi en este proceso, quienes inculcaron sus consejos, valores y principios en la persona que soy hoy. Gracias a ustedes, logre alcanzar esta meta.

Agradezco a mis profesores, que nos brindaron su conocimiento y apoyo durante la carrera. Su guía me ayudó a convertirme en un profesional integral.

Agradezco a mis amigos y compañeros, que me brindaron su apoyo incondicional en medio del proceso. Su amistad y aliento fueron fundamentales para este éxito.

Tabla de Contenido

	Pág.
Introducción	12
2. Objetivos.....	14
2.1 Objetivo General.....	14
2.2 Objetivos Específicos.....	14
3. Revisión de literatura sobre redes neuronales artificiales con aprendizaje supervisado.....	15
3.1 Metodología empleada para la revisión de literatura.....	15
3.2 Resultados de la revisión de literatura sobre RNA con aprendizaje supervisado.....	15
3.1.1 Redes neuronales con aprendizaje supervisado.....	16
4. Apoyar en la instrumentación del segmento de viga de estudio.....	19
4.1 Metodología aplicada.....	19
4.2 Resultados.....	21
5. Toma de datos de temperatura en el segmento de viga.....	23
5.1 Capacitación en los equipos y/o herramientas para el proyecto.....	23
5.2 Ajuste en los equipos y/o herramientas en el proyecto.....	24
5.3 Uso de los equipos y/o herramientas:	25
5.4 Procesamiento de imágenes.....	26
6 Implementar una red neuronal con aprendizaje supervisado para la estimación de la temperatura interna de un bloque de concreto.....	29
6.1 Metodología.....	29
6.2 Alcance de la implementación de la RNA	34
6.3 Resultados de la implementación de la RNA con aprendizaje supervisado	35

7	Conclusiones.....	37
	Referencias Bibliográficas.....	39
	Apéndices.....	41

Lista de Tablas

	Pág.
Tabla 1. <i>Clasificación grado de importancia de los 62 artículos de estudio.</i>	16
Tabla 2. <i>Tipo de aprendizaje supervisado y modelo de red.</i>	18
Tabla 3. <i>Condensación de datos de granulometría de los agregados gruesos.</i>	21
Tabla 4. <i>Condensación de datos de granulometría de los agregados finos.</i>	22
Tabla 5. <i>Composición del suelo agrados gruesos.</i>	22
Tabla 6. <i>Composición del suelo agregados finos.</i>	22
Tabla 7. <i>Resultados de confiabilidad y error de una capa de salida (temperatura termopar) y capa de entrada (temperatura ambiental, radiación y foto térmica)</i>	35
Tabla 8. <i>Resultados de confiabilidad y error de una capa de salida (temperatura termopar) y dos capas de entrada combinación de (temperatura ambiental, radiación y foto térmica)</i>	36
Tabla 9. <i>Resultados de confiabilidad y error de una capa de salida (temperatura termopar) y tres capas de entrada juntamente (temperatura ambiental, radiación y foto térmica)</i>	36

Lista de Figuras

	Pág.
<i>Figura 1. Inserción del cableado de los termopares en la tarjeta de relés, forma de situar en la ranura de la DAQ, visualización del Canal.....</i>	20
<i>Figura 2. Forrado de los termopares en papel vinipel e instalación de tarjeta de relés en la ranura de la (DAQ).....</i>	20
<i>Figura 3. Viga tipo I.....</i>	24
<i>Figura 4. Estaciones Meteorológica y Consola Vantage Pro2</i>	24
<i>Figura 5. Hydra Serie III Data Acquisition Unit (DAQ).....</i>	25
<i>Figura 6. Cámara FLIR C5</i>	25
<i>Figura 7. Inserción de puntos para lectura de temperatura usando FLIR Tools.....</i>	26
<i>Figura 8. Marcación de puntos desde arriba hacia abajo y reporte termográfico imagen MSX térmico, con espectro visible con la temperatura de cada punto.</i>	27
<i>Figura 9. Inserción de puntos de arriba hacia abajo con la herramienta temperatura de punto.....</i>	28
<i>Figura 10. Reporte en PDF luego de la inserción de los 10 puntos.....</i>	28
<i>Figura 11. Bloque de concreto escenario 1.....</i>	30
<i>Figura 12. Bloque de concreto escenario 2.....</i>	30
<i>Figura 13. Bloque escenario 3.....</i>	31
<i>Figura 14. Bloque de concreto con inserción de termopares, superior, central y lateral.</i>	31
<i>Figura 15. Flujoograma Backpropagation.....</i>	33

Lista de Apéndices

	pág.
Apéndice A. Resumen 8 artículos, con sus autores, título, enlace, publicación y un resumen destacando los aspectos más relevantes de cada uno. Estos artículos fueron obtenidos a través de la plataforma Scopus.....	41
Apéndice B. <i>Enlace de la implementación del código de la RNA, de las 3 capas de entradas (radiación, temperatura ambiente y foto térmica), y la capa de salida (termopar).</i>	42

Glosario

Aprendizaje supervisado: un tipo de aprendizaje automático en el que el modelo se entrena con un conjunto de datos etiquetados. Los datos etiquetados consisten en pares de entradas y salidas. El modelo aprende a asociar las entradas con las salidas correctas.

Capa entrada: una variable que se introduce en una red neuronal.

Capa oculta: permiten a la red neuronal aprender relaciones complejas entre las entradas y las salidas. La elección del número de capas ocultas y el número de neuronas en cada capa es importante para el rendimiento de la red neuronal.

Capa salida: una variable que se genera por una red neuronal.

Error: la diferencia entre la salida real y la salida deseada de una red neuronal.

Parámetro: un valor que se ajusta durante el entrenamiento de una red neuronal.

Red neuronal: un modelo matemático que se inspira en la estructura del cerebro humano. Está formado por una serie de nodos conectados entre sí, que representan neuronas.

Termopar: un dispositivo que convierte la diferencia de temperatura entre dos puntos en una diferencia de potencial eléctrico.

Resumen

Título: Apoyo en la instrumentación de una viga e implementación de una Red Neuronal con aprendizaje supervisado para estimar temperatura en el concreto dentro del proyecto de Investigación VIE-UIS No 2823.

Autor: Luis Dario Villamil Contreras**

Palabras Clave: Red Neuronal, Aprendizaje Supervisado, Termopar, Temperatura, Puente, Viga.

Descripción: En este trabajo, se describe el proceso de instalación de 40 termopares (TCs) en un segmento de viga I; del mismo modo, se presenta el diseño e implementación de una red neural artificial (RNA) con aprendizaje supervisado para estimar la temperatura dentro de un bloque de concreto, a partir de los datos obtenidos de una estación meteorológica y de mediciones de temperatura sobre un bloque de concreto obtenidas con TCs. Estas actividades fueron realizadas en el marco del proyecto de investigación VIE-UIS No. 2823 titulado “Sistema piloto para el monitoreo térmico en puentes de viga cajón en Colombia”. Durante el desarrollo de esta pasantía de investigación, inicialmente se apoyó en la construcción de una viga I. Seguidamente, se realizó la toma de datos de temperatura en la viga I. La colaboración en la campaña de toma de datos sobre la viga I se realizó entre mayo y julio de 2023. Se finalizó con la implementación de una RNA con aprendizaje supervisado para estimar temperaturas dentro del bloque de concreto. En este contexto, fue necesario llevar a cabo una revisión bibliográfica enfocada en la aplicación de redes neurales con aprendizaje reforzado usadas para estimar temperaturas en el concreto. Para obtener los datos experimentales de temperatura (viga I), fue indispensable el uso de un dron equipado con cámara térmica, sensores de medición de temperatura (TCs), una cámara termográfica fija y una estación meteorológica. Con la implementación de la red neural fue posible obtener un 95.4 % de índice de confianza, teniendo en cuenta el uso total de datos. Por otra parte, se puede afirmar que, el reconocimiento de patrones resulta ser eficaz si se utilizan correctamente las técnicas de Backpropagation (algoritmo de entrenamiento usado en RNA). Se logró evidenciar que es posible identificar variables ambientales que influyen en la estimación de la temperatura interna del bloque de concreto estudiado.

** Facultad de Ingenierías Físicomecánicas. Escuela de Ingeniería Civil. Director: Oscar Javier Begambre, PhD. en Ingeniería Civil Codirector: José Miguel Benjumea, Ph. D. in Civil and Environmental Engineering.

Abstract

Title: Assistance in the instrumentation of a beam and the implementation of a neural network with supervised learning to estimate a concrete temperature within the research project VIE-UIS No. 2823.

Author(s): Luis Dario Villamil Contreras

Key Words: Neural Network, Supervised Learning, Temperature, Thermocouple, Bridge, Beam.

Description: This work describes the installation process of 40 thermocouples (TCs) in a segment of I-beam; likewise, it presents the design and implementation of an artificial neural network (ANN) with supervised learning to estimate the temperature inside a concrete block, based on data obtained from a weather station and temperature measurements on a concrete block obtained with TCs. It ended with the implementation of an ANN with supervised learning to estimate temperatures inside the concrete block. In this context, it was necessary to carry out a literature review focused on the application of neural networks with reinforced learning used to estimate temperatures in concrete. To obtain the experimental temperature data (beam I), the use of a drone equipped with a thermal camera, temperature measurement sensors (TCs), a fixed thermographic camera and a weather station was indispensable. With the implementation of the neural network, it was possible to obtain a 95.4% confidence index, taking into account the total use of data. On the other hand, it can be affirmed that pattern recognition is effective if the Backpropagation techniques (training algorithm used in ANN) are used correctly. It is possible to identify environmental variables that influence the estimation of the internal temperature of the concrete block studied.

* Degree Work

** Faculty of Physical-Mechanical Engineering. School of Civil Engineering. Director: Oscar Javier Begambre, PhD. in Civil Engineering Codirector: José Miguel Benjumea, Ph. D. in Civil and Environmental Engineering.

Introducción

“Las redes neuronales artificiales son unas estructuras matemáticas que intentan imitar el funcionamiento de un cerebro biológico” (Acuña Torres et al., 2014).

En la actualidad, las redes neuronales han sido aplicadas satisfactoriamente en muchos campos de la ciencia. En el caso de la detección del daño estructural en las construcciones, las redes neuronales empiezan a ser utilizadas como una herramienta prometedora (Pérez González y González Valdés, 2008).

Con la implementación de la RNA, siendo un método no destructivo, es posible conocer la temperatura interna para el monitoreo térmico de puentes. Las cargas térmicas en los puentes son fenómenos ocasionados por eventos ambientales a los que la infraestructura está expuesta diariamente, y estas pueden variar con el tiempo debido a las fluctuaciones de temperatura (Álvarez, 2011). Es esencial comprender los diferentes tipos de temperaturas en juego, como la temperatura ambiental y la temperatura interna, así como su impacto en las estructuras y los efectos que generan. Además, se debe determinar la temperatura promedio, ya que las altas temperaturas pueden provocar dilataciones, mientras que las bajas temperaturas pueden causar contracciones. En consecuencia, es fundamental comprender el objeto de análisis y los factores que generan estas modificaciones en las estructuras de los puentes (Álvarez, 2011).

Teniendo en cuenta lo anterior, y siguiendo el planteamiento del proyecto de investigación VIE-UIS No. 2823 titulado “Sistema piloto para el monitoreo térmico en puentes de viga cajón en Colombia”. Este documento presenta las actividades de: revisión literaria sobre la implementación de RNA con aprendizaje supervisado empleada en la estimación de temperatura del concreto (ver sección 2); apoyo en la instrumentación del segmento de viga I de estudio, abordado en la sección

3; toma de datos de temperatura, con el uso de cámaras termográficas y el dron, para el procesamiento de las imágenes térmicas mediante el software, tratado en la sección 4 y, posteriormente, realizar la implementación de la RNA para la estimación de la temperatura interna de un bloque de concreto. Finalmente, las conclusiones del trabajo se presentan en la sección 6.

2. Objetivos

2.1 Objetivo General

Apoyar en la instrumentación de una viga e implementar de una red neural con aprendizaje supervisado para estimar temperatura en el concreto dentro del proyecto de investigación VIE-UIS No. 2823.

2.2 Objetivos Específicos

Apoyar en la instrumentación del segmento de viga de estudio.

Colaborar en la toma de datos de temperatura en el segmento de viga, utilizando cámaras termográficas y el procesamiento de las imágenes térmicas mediante software.

Realizar la revisión literaria para la implementación de redes neuronales con aprendizaje supervisado empleadas en la estimación de temperatura del concreto.

Implementar una red neuronal con aprendizaje supervisado para la estimación de la temperatura interna de un bloque de concreto.

3. Revisión de literatura sobre redes neuronales artificiales con aprendizaje supervisado.

La metodología empleada en esta pasantía se basó en un enfoque de investigación exhaustiva. Para la recopilación de información sólida y actualizada, se utilizó *Scopus* (Elsevier, 2013) como fuente principal de investigación, adicionalmente, para fortalecer la información, se utilizó *Google Académico*, a fin de identificar artículos académicos pertinentes relacionados con la RNA

3.1 Metodología empleada para la revisión de literatura.

Por medio de la herramienta de la biblioteca virtual UIS: *Scopus*, se realizó una investigación bibliográfica de artículos relacionados con redes neurales artificiales. Esta base de datos funciona mediante cadenas de búsqueda, en las que es posible encontrar gran variedad de información, por lo que resulta necesario aplicar una serie de filtros para poder acceder a la información más importante.

Se inició la búsqueda con las palabras “redes neuronales artificiales” (RNA) y se obtuvieron 251.534 documentos; seguidamente, se aplicó un segundo filtro con las palabras “RNA en puentes”, reduciendo los resultados a 119 artículos. Posteriormente, se aplicó otro tercer filtro por redes neuronales artificiales en puentes de concreto y temperatura, del que se obtuvieron 87 resultados, los cuales, fueron exportados en formato CSV, en Excel. Finalmente, se implementó un último filtro, con el cual se descartaron aquellos documentos que mediante el aplicativo *Scopus* no referenciaba autores, quedando así, 62 para revisión.

3.2 Resultados de la revisión de literatura sobre RNA con aprendizaje supervisado.

Los resultados obtenidos a partir de las lecturas realizadas ofrecieron una visión esclarecedora sobre las RNA.

Una vez clasificado el material (62), se procedió con la interpretación y revisión cuidadosa de los artículos seleccionados, con un enfoque en la extracción de información relevante y significativa para el avance del proyecto. Esta estrategia permitió la obtención de datos precisos y fundamentados que sirvieron como base sólida para el análisis y desarrollo de la pasantía (Tabla 1).

Tabla 1

Clasificación grado de importancia de los 62 artículos de estudio.

Grado	N° Artículo	%
Muy importante	4	6%
Importante	2	3%
Importante en conjunto No Supervisado y Supervisado	2	3%
Algo importante	1	2%
Poco Importante	21	34%
No es importante	32	52%
Total	62	100%

Se presenta las características más relevantes de los artículos revisados, de los cuales se extrajeron datos claves, como título, año, enlace, autores y resumen resaltando lo más importante de cada uno (consultar apéndice A).

A continuación, se presenta una exposición de las RNA y de las RNA'S con aprendizaje supervisado, de acuerdo con su arquitectura, el tipo de aprendizaje y el algoritmo de entrenamiento a usar. Estas características son importantes para la identificación de patrones en los datos de temperatura y para hacer predicciones.

3.1.1 Redes neuronales con aprendizaje supervisado.

En el proceso de aprendizaje o entrenamiento de una red neuronal, y por medio de un conjunto de entradas, se ajustan adecuada e internamente todos y cada uno de los pesos agregado,

así para lograr la salida deseada, de modo que la red pueda responder posteriormente por sí sola a situaciones diferentes a las aprendidas (Matich, 2001).

Este aprendizaje en las redes neuronales es lo que determina las ventajas (y también las desventajas) de estos sistemas. Si la red está bien configurada, y gracias a las operaciones masivamente paralelas de cada nodo, puede trabajar con datos incompletos o difícil de predecir, porque tiene un cierto grado de memoria asociativa que le permite generalizar su comportamiento ante cierta entrada, si esta entrada es razonablemente parecida a aquéllas para las que ha sido entrenada (Izaurieta y Saavedra, 2000).

3.1.1.1 Aprendizaje Supervisado. Hace referencia al proceso mediante el cual la RNA puede hacer predicciones basadas en patrones que aprende continuamente de la base de datos. Es decir, se trata de automatizar el proceso de creación de modelos analíticos que permite que la red se adapta a situaciones nuevas (Villegas Effio, 2019).

3.1.1.2 Arquitectura de la RNA's con aprendizaje supervisado. Se denomina arquitectura a la topología, estructura o patrón de conexionado de una red neuronal con aprendizaje supervisado. En una RNA los nodos se conectan por medio de sinapsis, esta estructura de conexiones sinápticas determina el comportamiento de la red. Las neuronas se suelen agrupar en unidades estructurales que denominaremos capas. Las neuronas de una capa pueden agruparse, a su vez, formando grupos neuronales, Así el conjunto de una o más capas constituye la red neuronal (Arcos Guerrero, 2008).

Se distinguen tres tipos de capas: de entrada, de salida y ocultas. Una capa de entrada o sensorial está compuesta por neuronas que reciben datos o señales procedentes del entorno (por ejemplo, proporcionados por sensores). Una capa de salida es aquella cuyas neuronas proporcionan la respuesta de la red neuronal (sus neuronas pueden estar conectadas a efectores. Las RNA

Backpropagation son aquellas cuyas neuronas se organizan en varias capas (Arcos Guerrero, 2008).

3.1.1.3 Tipos de RNAs con aprendizaje Supervisado. En la siguiente tabla se muestra algunos de los modelos de redes neuronales más conocidos con aprendizaje supervisado.

Tabla 2

Tipo de aprendizaje supervisado y modelo de red.

Tipo de aprendizaje supervisado	Modelo de red
Aprendizaje por corrección de error.	Perceptron
	Adaline/madaline
	Backpropagation
	Brain-state-in a box
Aprendizaje por refuerzo	Counterpropagation
	Linea reward penalty
	Associative rew. Penalty
Aprendizaje estocástico	Adaptive heuristic critic
	Boltzmann machine
	Cauchy machine

Nota. Cubas Glenn y Borrero del Rio (2007, p. 33).

3.1.1.4. Algoritmo Backpropagation. La red Backpropagation es un tipo de red con aprendizaje supervisado. Su función es aprender de un conjunto predefinido de pares entrada-salida. Utilizando un ciclo de propagación-adaptación de dos fases: en la primera de ellas se aplica un patrón a la entrada de la red como estímulo; este se propaga desde la primera capa a través de capas intermedias u ocultas, hasta que se produzca una salida. La señal de salida se compara con la salida deseada y se determina un error para cada salida (Toral Barrera, 2016). El error comienza en la capa de salida y se propaga hacia atrás, pasa por las capas ocultas hasta llegar a la capa de entrada; el aprendizaje involucra un ajuste de los pesos comparando la salida deseada, esto se basa en la regla de aprendizaje de corrección del error, esto es una generalización del algoritmo del

error mínimo cuadrado (Monsalve Espinosa y Rodríguez Otero, 2019). Se convierte este error en una derivada de este y se propaga este dato a la capa anterior, la importancia de este proceso consiste en que, a medida que se entrene la RNA, las neuronas de las capas ocultas se organizan a sí misma de tal modo que las diferentes neuronas puedan reconocer distintas características del conjunto de entradas (Prieto et al. 2016).

4. Apoyar en la instrumentación del segmento de viga de estudio.

La construcción de la viga tipo I es un proceso meticuloso que comienza con una fase crucial de diseño y planificación. En esta etapa es fundamental determinar las dimensiones de la viga, la carga que debe soportar y la elección del material. Como se observa en la figura 3, se empleó polisombra verde para disminuir la radiación reflejada por la terraza donde está ubicada la viga. Este proceso fue ejecutado por el Tutor Pedro Cavadia, con diferentes tonalidades (verde, azul y negra), todas de igual densidad del 80% y la de mejor desempeño fue la de color verde.

La viga se construyó a la intemperie por que el interés era conocer el gradiente de temperatura ocasionado por las fluctuaciones del clima.


4.1 Metodología aplicada.

En este caso, se realizaron las cotizaciones necesarias para hallar la constructora y los materiales necesarios para la creación de la viga tipo I, la cual estará ubicada en la Universidad Industrial de Santander. Luego, fue necesario realizar la comprobación del funcionamiento de los cuarenta termopares, una vez emitida la señal de comprobación en la DAQ, se insertan en la tarjeta de relés, que luego serán introducidas en la ranura de la Hydra Series III Data Acquisition Unit (DAQ) (Figura 1).

Luego, se procede con la marcación de los termopares de la 101-110,111-120, 201-210 y 301-310, esto con el fin de identificar si su funcionamiento es correcto, cada uno tendrá un canal para mayor supervisión, de acuerdo, a la numeración asignada, también, podemos corroborar que el canal coincida (Figura 1).

Figura 1

Inserción del cableado de los termopares en la tarjeta de relés, forma de situar en la ranura de la DAQ, visualización del Canal



Se procede con la protección de los termopares con papel vinipel. Posteriormente, se conecta a la DAQ, esto, con la ayuda de unas abrazaderas; seguidamente, se hace el chequeo y se evidencia que está tomando los datos de manera correcta (Figura 2).

Figura 1

Forrado de los termopares en papel vinipel e instalación de tarjeta de relés en la ranura de la (DAQ).



Por otra parte, se llevó a cabo la granulometría del material utilizado en la construcción de la viga tipo I, dando continuidad de apoyo en el proyecto de investigación **VIE 2823**. Con el desarrollo de este ensayo, se pretende lograr la determinación cuantitativa de la distribución de los tamaños de las partículas que componen los agregados gruesos y finos, este proceso fue efectuado a través del tamizado siguiendo las indicaciones de la INV E-213-13 (INVIAS, 2021) (Tabla 3 y 4). Una vez construida la viga, se empezará la toma de datos, teniendo en cuenta el uso de los cuarenta termopares, el dron, la cámara térmica, el uso de la DAQ, y la estación meteorológica.

4.2 Resultados.

Una vez construida la viga tipo I, se completa una de las etapas más importantes del proyecto. Esta viga servirá como la base sobre la cual se instalarán los cuarenta termopares estratégicamente puestos, diseñadas para registrar datos de temperatura en intervalos regulares. La importancia de la viga radica en que será el punto de referencia esencial para la aplicación de una red neuronal artificial. Esta RNA permitirá precisamente determinar la temperatura interna de la viga tipo I en tiempo real, brindando información crucial para el monitoreo y control térmico de la estructura del proyecto.

Tabla 3

Condensación de datos de granulometría de los agregados gruesos.

Tamiz	Retenido Wr (g)	Retenido Acumulado	Pasa	%Retenido	% Pasa
1 1/2"	0	0	5087	0.00%	100.00%
1"	116	116	4971	2.28%	97.72%
3/4"	1210	1326	3761	26.07%	73.93%
1/2"	3137	4463	624	87.73%	12.27%
3/8"	492	4955	132	97.41%	2.59%
#4	117	5072	15	99.71%	0.29%
Fondo	15	5087	0	100.00%	0.00%
Σ	5087 g				

Nota. Esta tabla muestra los resultados de ensayos de agregados gruesos.

Tabla 4

Condensación de datos de granulometría de los agregados finos.

Tamiz	Retenido Wr (g)	Retenido Acumulado	Pasa	%Retenido	% Pasa
1/2"			1214		100.00%
3/8"	13	13	1201	1.07%	98.93%
#4	21	34	1180	2.80%	97.20%
#10	97	131	1083	10.79%	89.21%
#18	201	332	882	27.35%	72.65%
#50	838	1170	44	96.38%	3.62%
#60	7	1177	37	96.95%	3.05%
#100	30	1207	7	99.42%	0.58%
#200	0	1207	7	99.42%	0.58%
Fondo	7	1214	0	100.00%	0.00%
Σ	1214 g				

Nota. Esta tabla muestra los resultados de ensayos de agregados finos.

De la muestra de agregados gruesos, se obtuvo como resultado un 99.71% de gravas (Tabla 5), según la tabla de composición del suelo. Los agregados finos se clasifican en arenas según la tabla de composición del suelo, tiene un 96.62% Arena (Tabla 6).

Tabla 5

Composición del suelo agregados gruesos.

%Gravas	99.71%
%Finos	0.00%
%Arenas	0.29%

Tabla 6

Composición del suelo agregados finos.

%Grava	2.801%
%Fino	0.58%
%Arena	96.623%

5. Toma de datos de temperatura en el segmento de viga.


En esta sección se describen los equipos y procedimientos utilizados para el registro de temperaturas superficiales, internas y ambiental de la viga mostrada en la Figura 3. Los equipos y programas empleados para registrar y analizar los datos de temperatura fueron:

- El dron DJI MAVIC 2 ENTERPISE ADVANCED (EU) y la cámara termográfica FLIR C5, se emplearon para la toma de la temperatura superficial.
- DAQ se utilizó para mostrar el reporte de la temperatura de las TCs (temperatura interna).
- La estación meteorológica, a través de su consola Vantage Pro2, para la recolección de registros de temperatura y radiación solar.

Los cuales son necesarios para el debido procesamiento de las imágenes térmicas mediante softwares como el FLIR Tools (FLIR Systems Inc, 2018). DJI Thermal Analysis Tool 3 (DJI, 2023) respectivamente. Para alcanzar este objetivo, se llevó a cabo las siguientes etapas

5.1 Capacitación en los equipos y/o herramientas para el proyecto.

Para el manejo de los equipos y los procedimientos empleados, fue necesaria la capacitación sobre instrumentación del ingeniero Pedro Juan Cavadia Ibáñez, esta instrucción resultó fundamental para el desarrollo de la pasantía VIE-UIS No. 2823 para las diferentes tomas de datos en el segmento de viga tipo I. En primer lugar, se realizaron algunas pruebas de ensayos con el vehículo aéreo no tripulado (dron) DJI MAVIC 2 ENTERPISE ADVANCED (EU), se usó primero para llevar el registro fotográfico en la construcción del segmento de viga. Luego de la construcción de la viga, fue necesario el dron para llevar el registro de la temperatura externa mediante la cámara termográfica (en la cara lateral derecha y superior de la viga).

Figura 3*Viga tipo I***5.2 Ajuste en los equipos y/o herramientas en el proyecto.**

Se hace el respectivo ajuste en las estaciones meteorológicas, por medio, de su consola Vantage Pro2, respectivamente (Figura 4). Esta consola registra y muestra los datos meteorológicos por la estación, esto es posible ya que transmite los datos por radiofrecuencia de baja potencia, de igual forma, la estación meteorología es ubicada hacia el norte con la ayuda de una brújula.

Figura 2*Estaciones Meteorológica y Consola Vantage Pro2*

Una vez realizada la primera toma de datos y verificación del funcionamiento de los termopares con el apoyo del sistema DAQ (Figura 5), y teniendo en cuenta que sus resultados sean

favorables, se da inicio con el archivo de la toma de datos registrada por los termopares que están debidamente conectadas a estas. Se lleva un control de cada media hora durante todo el día.

Figura 3

Hydra Serie III Data Acquisition Unit (DAQ)



5.3 Uso de los equipos y/o herramientas:

Una vez construida la viga, se tomó el tiempo de fraguado. Los equipos usados para el monitoreo, toma de datos y registro del proyecto fueron: el dron, la cámara termográfica FLIR C5 (Figura 6) y el registro llevado por el sistema DAQ. Se procede con la toma de los datos y su ejecución en el registro fotográfico para los respectivos ajustes y monitoreo. Además, se implementa los diferentes protocolos del uso de los equipos mencionados anteriormente, asimismo, se adjunta el listado de instrumentos y materiales requeridos en el proyecto VIE-UIS No. 2823.

Figura 4

Cámara FLIR C5



5.4 Procesamiento de imágenes.


Por medio de turnos rotativos con otros auxiliares de investigación y adicionalmente con el acompañamiento del tutor Pedro Juan Cavadia, durante dos semanas, del 11 al 26 de julio del 2023 se llevó a cabo el registro fotográfico con ayuda de la cámara FLIR C5 y el dron; en un horario de las 6:30 a las 16:00; una vez obtenida la evidencia fotográfica, se procesa en un programa informático especializado en termografía capaz de crear informes de inspecciones (FLIR Tools), claro, siempre y cuando sean productos de FLIR, como en este caso lo es la cámara FLIR C5, la cual cuenta con licencia libre.

El programa FLIR Tools, entre otras funciones, permite la importación de imágenes desde la cámara vía USB, este ejercicio ayuda a hacer un análisis y ajuste de imágenes radiométricas, al tiempo que arroja una medida más precisa de la temperatura, genera informes en PDF, entre otros.

Adicionalmente, se realiza la importación de la imagen, el software las lee, y por medio del uso de las herramientas del lado izquierdo, se selecciona la opción de agregar medida del punto y se sitúa el punto en medio de las flechas que muestra la imagen.

Figura 5

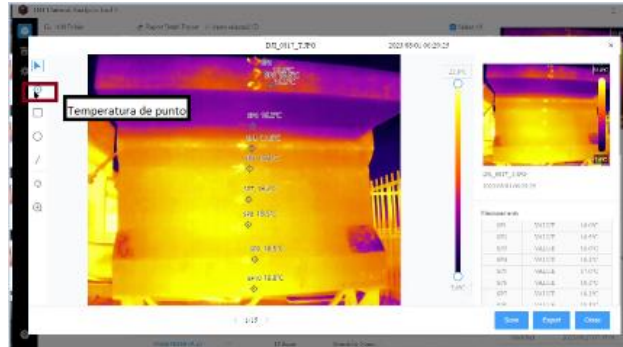
Inserción de puntos para lectura de temperatura usando FLIR Tools



Para empezar la marcación de puntos en la imagen se hace de arriba hacia abajo, debido a que los termopares también están ubicados en orden ascendente en la fotografía térmica lateral

Figura 7

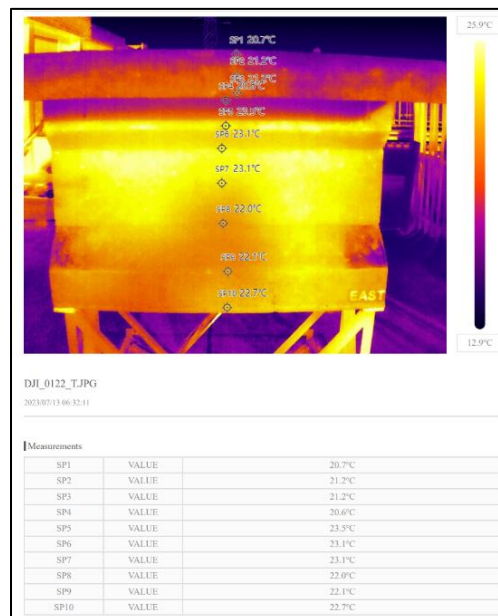
Inserción de puntos de arriba hacia abajo con la herramienta temperatura de punto.



El número de punto al igual que la FLIR son diez en la cara lateral de la viga, en medio de las flechas que se ven en la imagen. Para luego exportar e ir a la pantalla informe, luego “clic” en “Exportar PDF” para la imagen térmica seleccionadas, la cual contiene el resumen en orden y muestra la temperatura.

Figura 8

Reporte en PDF luego de la inserción de los 10 puntos



6 Implementar una red neuronal con aprendizaje supervisado para la estimación de la temperatura interna de un bloque de concreto.

La implementación de una red neuronal con aprendizaje supervisado para la estimación de temperatura de un bloque de concreto es un proceso complejo, pero altamente efectivo en aplicaciones de monitoreo y control térmico en la construcción. Para desarrollar esta actividad, se empleó una serie de datos de temperatura interna de un bloque de concreto (Figura 14), previamente registrados por el ing. Pedro Cavadia (tutor de esta pasantía). El uso de RNA permite, una vez entrenada la red, pronosticar la temperatura interna a partir de, por ejemplo, los registros de temperatura realizados con una cámara termográfica y el dron (información obtenida sobre la superficie del bloque). A continuación, se describe la metodología empleada para entrenar la red y realizar las predicciones pertinentes.

6.1 Metodología.

Como ya se mencionó, dentro del proyecto se tenían datos tabulados de temperatura interna y externa obtenidos por termopares, datos de temperatura superficial del bloque de concreto tomados con la cámara termográfica FLIR C5; los registros de la temperatura ambiente y radiación solar, fueron conseguidos empleando la estación meteorológica, por medio, de su consola Vantage Pro2.

El proceso de implementación de la RNA se inició con los datos registrados para tres escenarios definidos anteriormente sobre el bloque de concreto (Figura 13). Estos escenarios incluyen los siguientes: el primer escenario, que implica el bloque de concreto en contacto directo con la placa, es decir, contacto de concreto con concreto (Figura 11).

Figura 9

Bloque de concreto escenario 1



En el segundo escenario, el bloque se eleva aproximadamente 3 cm sobre dos láminas de icopor Figura 12.

Figura 10

Bloque de concreto escenario 2



El tercer escenario implica el bloque elevado a una altura de 30 cm mediante el apoyo sobre dos bloques de concreto, tal como se ilustra en la Figura 12.

Figura 11


Bloque escenario 3



A continuación, se organizó, en un archivo (Excel) la siguiente información: temperatura registrada en los termopares y en las fotografías térmicas de la parte lateral, superior y frontal del bloque de concreto (Figura 14). Así mismo, se consignó la temperatura ambiente, la velocidad y dirección del viento, la radiación solar y la precipitación (registradas con la estación meteorológica Davis Vantage Pro2). Luego, se creó un archivo csv para separar los decimales con punto. Estos datos fueron la base para el entrenamiento y validación de la RNA.

Figura 12

Bloque de concreto con inserción de termopares, superior, central y lateral.



La programación de la RNA Backpropagation se realizó por medio de una extensión del software Python (Python Software Foundation, 2023), denominada *Google Colab*, que permitió escribir y ejecutar el código a través del navegador web (Google Chrome). Por medio de la librería *TensorFlow*, se implementó el diagrama de flujo mostrado en la figura 16.

A continuación, se procede al entrenamiento de la red con 2000 iteraciones, utilizando como entradas de la red neuronal la temperatura ambiente, radiación solar y foto térmicas lateral, frontal y superior. También se define el número de capas ocultas, que son 20, 10 y 5 favoreció la eficiencia computacional al lograr un equilibrio apropiado entre la capacidad del modelo y su adaptación a los datos de entrenamiento específicos. Esta configuración, al mantener un número óptimo de capas ocultas, potencia la capacidad del modelo para generalizar nuevos datos (Navarro Bellido, 2023). Estas actúan como un filtro que ayuda a la red a identificar las características más relevantes y a ajustarse un patrón. Como resultado, se obtiene la capa de salida, la cual se relaciona con los datos registrados por los termopares y se ajusta por lo captado por la RNA con un valor aceptable (Figura 16).

La RNA se entrenó usando el 70% de los datos recopilados del bloque de concreto, mientras que el 30% restante se usa para la validación. Es importante mencionar que la RNA, se entrenó con el propósito de predecir la temperatura interna en el bloque de concreto.

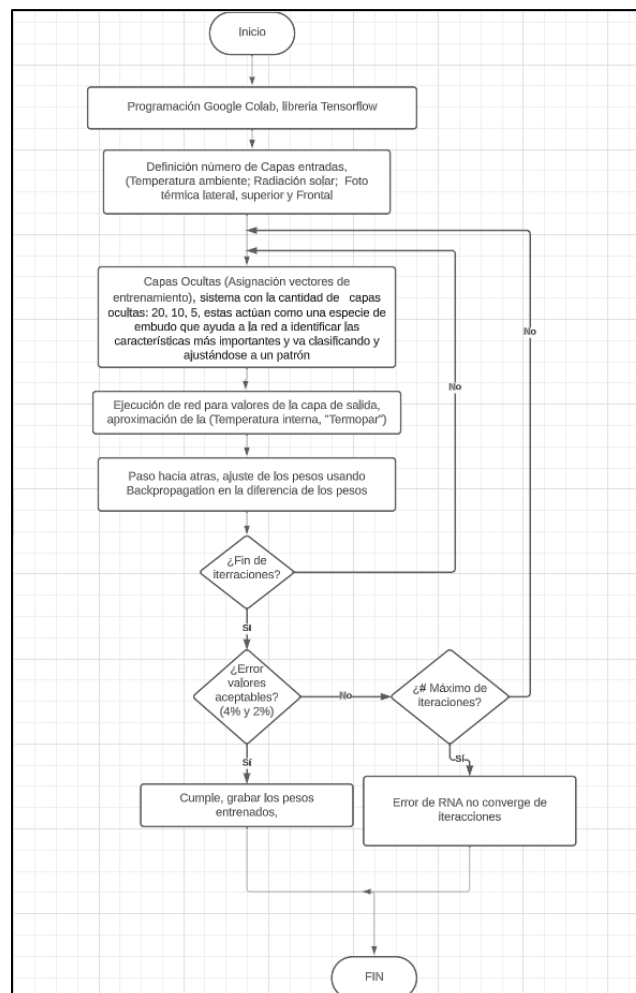
Para evaluar la eficiencia de la RNA, se implementó el ciclo for que calculo la asertividad. Este ciclo toma los datos obtenidos, realiza iteraciones para compararlos y analizarlos, y finalmente determino la cantidad de aciertos entre los datos de entrada y salida. Esto proporciona una medida de confiabilidad y eficacia de la RNA en el análisis de datos entre las capas de entrada y salida. Además, se realiza un ajuste del error entre lo registrado por los termopares (temperatura

interna) y las capas de entrada de la RNA (Temperatura ambiente, radiación solar, foto térmica lateral, superior y frontal).

Para obtener estos resultados, se llevó a cabo una comparación entre las capas de entradas (radiación, temperatura ambiente y fototérmicas lateral, superior y frontal) y la capa de salida, Este proceso permitió determinar la relación y comportamiento entre ambas capas. El entrenamiento se hizo desde el 11 de julio hasta el 28 de julio de 2023.

Figura 13

Flujograma Backpropagation.



6.2 Alcance de la implementación de la RNA

Esta investigación tiene como objetivo principal la aplicación de una red neuronal artificial (RNA) con el algoritmo de Backpropagation para la predicción de temperatura interna en el bloque de concreto. El propósito específico de esta RNA es proporcionar una herramienta efectiva y confiable para el monitoreo y control térmico.

El alcance de este proyecto abarca los siguientes aspectos:

- **Recopilación de datos:** Se recopilieron datos de temperatura interna del bloque de concreto a través de sensores y uso equipos nombrados en la sección 4
- **Preprocesamiento de datos:** Los datos recopilados se procesan y limpian para eliminar ruidos y valores atípicos.
- **Diseño de la Red Neuronal:** Se diseñará una RNA utilizando el algoritmo de Backpropagation como método de entrenamiento. Se determinará la arquitectura de la red, incluyendo el número de capas entradas (temperatura ambiente, radiación y foto térmicas lateral, superior y lateral); ocultas (sistema de 20,10 y 5). Estas actúan como como un filtro que ayuda a la red a identificar las características más importantes y ajustarse a un patrón, y capa de salida la cual se relaciona con los datos registrados por los termopares y se ajusta por lo captado por la RNA con un valor aceptable.
- **Entrenamiento de la RNA:** Se llevará a cabo el proceso de entrenamiento de la RNA utilizando los datos recopilados en el bloque de concreto. La RNA aprenderá a relacionar las capas entradas como la temperatura ambiente, la radiación solar y foto térmicas lateral, superior y frontal, con la capa de salida que son la temperatura por los sensores (termopares lateral, frontal y superior).

- Validación y Evaluación: Se evaluará la confiabilidad del modelo utilizando datos de validación independientes. Para medir la capacidad de la RNA de predecir la temperatura interna en diferentes condiciones.
- Optimización y ajuste: Se realizará ajustes en el error y optimizaciones en la RNA si es necesario para mejorar su rendimiento y precisión.

6.3 Resultados de la implementación de la RNA con aprendizaje supervisado

En resumen, al utilizar **la temperatura de la TC lateral como única capa de salida y la radiación como entrada**, se logró una confiabilidad del 20.0% con un error de 43.6%. Por otro lado, al emplear **la temperatura ambiente como variable de entrada**, se alcanzó una confiabilidad del 42.3% con un error de 10.7%. No obstante, los resultados más destacados se obtuvieron al emplear la **foto térmica lateral como capa de entrada**, se obtuvo una confiabilidad del 88% con un error del 5.1%, tal como se evidencia en la tabla 7.

Tabla 7

Resultados de confiabilidad y error de una capa de salida (temperatura termopar) y capa de entrada (temperatura ambiental, radiación y foto térmica)

1 capa entrada	Confiabilidad	Error	1 salida
Radiación	20.0%	43.6%	Termopar Lateral
Temperatura ambiente	42.3%	10.7%	
Foto lateral	88.0%	5.1%	

En esta sección con la aplicación de dos variables como capa de entrada, al evaluar conjuntamente las tres variables de entrada, a saber, la temperatura ambiental, la foto térmica y la radiación del bloque de concreto. Se observa los resultados que se realizaron entre las siguientes comparaciones: **la capa de salida es única que fue la temperatura del termopar**. La capa de entrada en el primer escenario fue **foto térmica y radiación**, donde se destaca una confiabilidad

del 94.3% y un error de 3.4%. El segundo **temperatura ambiental y foto térmica** logrando una confiabilidad notable del 84.1% con un error de 4.4%. Por último, la combinación de **radiación y temperatura ambiente**, demuestra una confianza de 47.4% con un error de 9.1%, como se muestra en la tabla 8.

Tabla 8

Resultados de confiabilidad y error de una capa de salida (temperatura termopar) y dos capas de entrada combinación de (temperatura ambiental, radiación y foto térmica)

2 capa entrada	Confiabilidad	Error	1 salida
Foto térmica lateral y Radiación	94.3%	3.4%	
Foto térmica lateral y Temperatura ambiente	84.1%	4.4%	Termopar Lateral
Radiación y Temperatura ambiente	47.4%	9.1%	

Al emplear las tres variables (capas de entradas: foto térmica, radiación y temperatura ambiente) resulta mucho más viable, obteniendo un 95.4 % confianza y un error del 2.7 con la capa de salida (temperatura termopar). Por tanto, es posible concluir que para poder conocer la temperatura interna de los bloques de concreto y para el buen funcionamiento de la RNA, es indispensable hacer uso de las tres variables juntas como se muestra en la tabla 9, ver Apéndice B.

Tabla 9

Resultados de confiabilidad y error de una capa de salida (temperatura termopar) y tres capas de entrada juntamente (temperatura ambiental, radiación y foto térmica)

3 capa entrada	Confiabilidad	Error	1 salida
Foto térmica lateral, Radiación y Temperatura Ambiente	95,4%	2,7%	Termopar Lateral

7 Conclusiones.

A partir de la revisión literaria, se puede inferir que el 12% de los artículos (8/62), que tratan de redes neuronales con aprendizaje supervisado y reforzado para la estimación de temperatura interna en el concreto, indica que los investigadores están interesados en conocer el comportamiento interno de los puentes debido a los esfuerzos térmicos, a causa de las variaciones de temperatura diurnas y anuales.

Los resultados obtenidos a través de la granulometría son esenciales en la industria de la construcción, especialmente en la preparación de hormigón o concreto; este ensayo, muestra la distribución de tamaño de partículas de los agregados. Los datos proporcionados son: 99.71% gravas y 96.62% arenas; la combinación de estos materiales resulta efectiva, dado que cumple con los estándares requeridos para la construcción de la viga tipo I, contribuyendo a la seguridad y durabilidad de la estructura.

Ahora bien, de acuerdo con el análisis de los datos obtenidos, entre la cámara FLIR C5 y el dron durante los 16 días fueron 6400 datos, los cuales se dividen en reporte individual por cada media hora en los 10 puntos, para un total de 20 tomas, se tomaron 2520 datos. Cabe resaltar que el proyecto continuará hasta el mes de noviembre.

Se observó que los resultados de reconocimiento de patrones resultan ser eficientes si se utilizan las técnicas de Backpropagation, ya que, para el caso analizado en este trabajo de grado, realiza una aproximación entre el resultado de la capa de salida que es lo registrado por la temperatura de los termopares y las capas de entradas que son radiación, fototérmicas (lateral, superior y frontal) y temperatura ambiente, con una eficacia del 95.4 % y error del 2.7. En

conclusión, es posible conocer las diferentes variables ambientales que influyen para determinar una aproximación en el comportamiento térmico interno del concreto.

Referencias Bibliográficas

- Acuña Torres, L., Moromi, A. V., & García, F. (2014). Uso de las Redes Neuronales Artificiales en el Modelado del Ensayo de Resistencia a Compresión de Concreto de Construcción según la Norma ASTM C39/C 39M. *Información tecnológica*, 215(4), 3-12.
- Álvarez, Á. (2011). La acción del fuego sobre las estructuras de concreto. *Construcción y Tecnología en Concreto*, 6, 1-7.
- Arcos Guerrero, D. F. (2008). Detección automática de registros sísmicos asociados al comportamiento del volcán galeras haciendo uso de redes neuronales artificiales. Trabajo de fin de grado, Universidad de Nariño.
- Cubas Glenn, G., & Borrero del Rio, O. (2007). Estudio y aplicaciones de las redes ART (teoría de la resonancia adaptiva). Universidad Tecnológica de Bolívar, Cartagena, Colombia.
- DJI. (2023). DJI Thermal Analysis Tool 3, 3.1.0. DJI.
- FLIR Systems Inc. (2018). FLIR TOOL, 6.4.18039.1003.
- Google Colab. (2023). Google Colaboratory.
- INVIAS. (2022). Sección 200-Agregados Pétreos.
- Izaurieta, F., & Saavedra, C. (2000). *Redes Neuronales Artificiales*. Universidad de Concepción, Chile.
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. GIAIQ, 41, 12-16.
- Monsalve Espinosa, D. E., & Rodríguez Otero, K. A. (2019). Algoritmo de una red neuronal profunda para la predicción de riesgos de morbilidad materna extrema (MME) en la E.S.E clínica de maternidad Rafael Calvo. Trabajo de fin de grado, Universidad Del Sinú Elías Bechara Zainum.

- Navarro Bellido, J. (2023). Modelos de aprendizaje automático en análisis de sentimiento: comparativa de rendimiento. Universidad Politécnica de Valencia.
- Pérez González, C. A., & González Valdés, J. (2008). Aplicación de un modelo de redes neuronales en la identificación del daño estructural en un puente vehicular. *Revista Científica Multidisciplinaria de Prospectiva*, 15(2), 176-188.
- Prieto, A., Prieto, B., Ortigosa, E. M., Ros, E., Pelayo, F., Ortega, J., & Rojas, I. (2016). Neural network: An overview of early research, current framework and new challenges. *Neurocomputing*, 214, 242-268.
- Python Software Foundation. (2023). Python Programming Language.
- Scopus. (2013). Elsevier.
- TensorFlow. (2023). TensorFlow: Open source machine learning framework.
- Toral Barrera, A. J. (2016). *Redes Neuronales*. Universidad de Guadalajara.
- Villegas Effio, M. A. (2019). Aplicación de redes neuronales para la predicción de la resistencia a la compresión del concreto según el ensayo de esclerometría. Universidad Peruana de Ciencias Aplicadas (UPC), Lima, Perú.

Apéndices

Apéndice A. Resumen 8 artículos, con sus autores, título, enlace, publicación y un resumen destacando los aspectos más relevantes de cada uno. Estos artículos fueron obtenidos a través de la plataforma Scopus.

Authors	Title	Year	Link	Publisher
Huang B., Kang F., Li J., Wang F.	Displacement prediction model for high arch dams using long short-term memory based encoder-decoder with dual-stage attention considering measured dam temperature	2023	https://www.scopus.com/inward/record.uri?eid=2-s2.0-85147189901&doi=10.1016%2fj.engstruct.2023.115686&partnerID=40&md5=a8e071ccad3b633bc922098ada15f0d2	Elsevier Ltd
<p>Resumen: El método de monitoreo de la salud estructural puede proporcionar información importante para evaluar el estado operativo de presas de concreto, al establecer modelos precisos para predecir el comportamiento de las presas de concreto con datos monitoreados. Este estudio propuso un modelo que utiliza un codificador-decodificador basado en una red de memoria a corto plazo con mecanismo de atención de dos etapas (DALSTM) para predecir el desplazamiento de presas de arco de hormigón. El codificador-decodificador basado en una red de memoria a corto plazo es una técnica de aprendizaje profundo que puede realizar predicciones de series de tiempo, y el mecanismo de atención de dos etapas se centra en la información clave en la serie de desplazamiento de la presa para mejorar el rendimiento. La efectividad y precisión del modelo de predicción propuesto se analizan en una presa de arco alto utilizando la temperatura medida en el cuerpo de la presa en lugar de las funciones para representar el efecto térmico.</p>				
Kwan OH B., Seon Park H., Gilicic B.	Time-dependent structural response estimation method for concrete structures using time	2023	https://www.scopus.com/inward/record.uri?eid=2-s2.0-85141813007&doi=10.1016%2fj.engstruct.2022.115493&partnerID=40&md5=78525956a2a2d20252d73e312b463369	Elsevier Ltd
<p>Resumen: En este estudio, se presenta un método de estimación de la respuesta estructural para evaluar la deformación a largo plazo, que puede servir como base para evaluar la seguridad estructural de estructuras de hormigón. Se identifican las características de la deformación a corto plazo causada por influencias ambientales y la deformación inelástica a largo plazo causada por una combinación de efectos reológicos e influencias ambientales. Para reflejar estas características de deformación a corto y largo plazo dependientes del tiempo en el método propuesto, se utilizan la deformación y la información de tiempo correspondiente recopiladas de un monitoreo de salud estructural (SHM). En el método propuesto, se utiliza una respuesta de deformación medida a partir de una estructura concreta y la información de tiempo correspondiente, incluido el año, mes, día y hora, se define mediante una red neuronal convolucional (CNN), que es una técnica de aprendizaje profundo. El método supone que las principales fuentes de deformación en la estructura son influencias ambientales, como la temperatura y la humedad, que tienen periodicidad diaria y estacional, y efectos reológicos en el hormigón, como la fluencia y la contracción, pero también supone que la información cuantitativa sobre estas fuentes no está disponible (por ejemplo, la temperatura y la humedad ambientales y la tensión reológica no se midieron de manera confiable). Por lo tanto, el método CNN desarrollado en este estudio se entrena únicamente con datos de deformación y tiempo recopilados durante varios años y se utiliza para estimar los valores de deformación dentro de un período de tiempo específico, por ejemplo, cuando se requiere la evaluación de seguridad de la estructura de concreto o en el caso de SHM, falla del sistema o pérdida de datos. El método presentado fue desarrollado y validado utilizando datos SHM de una estructura real instrumentada con sensores de tensión de fibra óptica. Además, la exploración de la constitución de la entrada de la CNN identificó el tipo de información temporal que es más eficaz en la estimación de la deformación a largo plazo del método desarrollado.</p>				
Ding W., Alharbi A., Almadhor A., Rahmayiezekavat P., Mohammadi M., Rashidi M.	Evaluation of the Performance of a Composite Profile at Elevated Temperatures Using Finite Element and Hybrid Artificial Intelligence Techniques	2022	https://www.scopus.com/inward/record.uri?eid=2-s2.0-85124805705&doi=10.3390%2fma15041402&partnerID=40&md5=78525956a2a2d20252d73e312b463369	American Concrete Institute
<p>Resumen: Es muy importante mantener en servicio las estructuras y elementos constructivos durante y después de la exposición a temperaturas elevadas. La investigación del comportamiento estructural de diferentes componentes y estructuras a temperaturas elevadas es un enfoque para manipular la capacidad de servicio de las estructuras durante la exposición al calor. Los conectores de canal son conectores de corte ampliamente utilizados no solo por sus atractivas propiedades mecánicas sino también por su trabajabilidad y su rentabilidad. En este estudio, se realizó una evaluación de elementos finitos (FE) en un modelo compuesto auténtico y se examinó el comportamiento del conector de corte del canal a temperatura elevada. Además, se ha desarrollado un nuevo algoritmo de inteligencia híbrida basado en un rasgo de selección de características con la incorporación de algoritmos de optimización de enjambre de partículas (PSO) y perceptrón multicapa (MLP) para predecir la respuesta de desplazamiento del canal. El algoritmo de inteligencia híbrida que utiliza redes neuronales artificiales se realiza a partir de datos derivados del estudio FE. Finalmente, los resultados numéricos obtenidos se comparan con los resultados de la máquina de aprendizaje extremo (ELM) y la función de base radial (RBF). El MLP-PSO presentó resultados notablemente precisos para la predicción del valor de deslizamiento a temperaturas elevadas. Los resultados demostraron la presencia activa de los canales, especialmente para mejorar la rigidez y la capacidad de carga de la viga compuesta. Aunque la altura mejora la ductilidad, la rigidez se reduce significativamente a temperaturas elevadas.</p>				
Almeida S.A., Jr., Guner S.	Review of Artificial Neural Networks and A New Feed-Forward Network for Anchorage Analysis in Cracked Concrete	2021	https://www.scopus.com/inward/record.uri?eid=2-s2.0-85139879513&partnerID=40&md5=a937f6c957c4a0b32e145754375874	American Concrete Institute
<p>Resumen: Las aplicaciones de informática suave a través de inteligencia artificial (IA) son cada vez más populares en la ingeniería civil. Desde la tecnología del hormigón hasta la ingeniería estructural, la IA ha proporcionado soluciones exitosas a diversos problemas y han reducido los costos computacionales al tiempo que han logrado una excelente precisión de predicción. En este estudio se presenta una revisión de los principales tipos de redes neuronales artificiales (RNA) utilizadas en ingeniería civil. Se describe cada tipo de ANN y se proporcionan ejemplos de aplicaciones. Como nueva contribución a la investigación, se desarrolla una red neuronal de avance profundo (FFNN) para predecir las capacidades de carga de anclajes adhesivos postinstalados instalados en hormigón fisurado, lo cual es desafiante y costoso desde el punto de vista operacional de lograr con métodos convencionales. Se discute el desarrollo de este FFNN. Se demuestra la influencia de varios parámetros en su rendimiento y se seleccionan los valores óptimos de los parámetros. Además, se presenta brevemente una metodología híbrida que combina técnicas de elementos finitos no lineales (NLFE) 2D con el FFNN desarrollado para tener en cuenta los efectos adversos de la vida real en el análisis de anclajes, incluido el agrietamiento del concreto, la flexión de vigas inducida por el viento y las temperaturas elevadas. Los resultados muestran que la red y la metodología desarrolladas pueden predecir de forma rápida y precisa las capacidades de carga de los anclajes adhesivos instalados en hormigón fisurado, teniendo en cuenta el daño causado por las grietas, con alta precisión. © 2021 Instituto Americano del Concreto</p>				
Khandel O., Soliman M., Floyd R.W., Murray C.D.	Performance assessment of prestressed concrete bridge girders using fiber optic sensors and artificial neural networks	2021	https://www.scopus.com/inward/record.uri?eid=2-s2.0-85085348424&doi=10.1080%2f15732479.2020.1759658&partnerID=40&md5=3c71e14cd9ea25ea0caee11fa4f62b4	Taylor and Francis Ltd.
<p>Resumen: Las actividades de monitoreo de la salud estructural (SHM) son esenciales para lograr una caracterización realista de los niveles de desempeño estructural del puente a lo largo de su vida útil. Estas actividades pueden ayudar a detectar daños estructurales antes de que se produzcan fallas estructurales a nivel de componentes o sistemas. Además de su aplicación en momentos discretos, los sistemas SHM también se pueden instalar para proporcionar datos precisos y confiables a largo plazo de manera continua durante toda la vida útil de un puente. Debido a su precisión superior y durabilidad a largo plazo en comparación con las galgas</p>				
Fils P., Jang S., Sherpa R.	Field implementation of low-cost RFID-based crack monitoring using machine learning	2021	https://www.scopus.com/inward/record.uri?eid=2-s2.0-8514769821&doi=10.12989%2fsmm.2021.8.3.257&partnerID=40&md5=d9c1b0a6c0ae70206dbf546540eafec	Techno-Press
<p>Resumen: A medida que la infraestructura civil sigue envejeciendo, la extensión de la vida útil se ha convertido en una solución financieramente atractiva debido al ahorro de costos en los proyectos de reconstrucción. Los esfuerzos para aumentar la vida útil de las estructuras incluyen técnicas de evaluación no destructiva (NDE) y monitoreo de la salud estructural (SHM). No obstante, la inspección visual se utiliza con más frecuencia debido al alto costo del equipo de otras técnicas y al requisito de inspección federal bienal. Recientemente, los dispositivos de identificación por radiofrecuencia (RFID) de bajo costo han llamado la atención para el monitoreo de grietas; sin embargo, aún no se había implementado en el campo. Este artículo presenta un algoritmo de monitoreo de grietas utilizando un sistema de detección desarrollado basado en RFID que emplea aprendizaje automático bajo variaciones de temperatura para su implementación en campo. Como bancos de pruebas se utilizaron dos edificios de hormigón armado, un estacionamiento y un edificio residencial con cimientos desmoronados. Se desarrolla una arquitectura de monitoreo de grietas basada en una red neuronal artificial (ANN) como algoritmo de estacionamiento y un edificio residencial con cimientos desmoronados. Se desarrolla una arquitectura de monitoreo de grietas basada en una red neuronal artificial (ANN) como algoritmo de aprendizaje automático y los resultados se comparan con un modelo de referencia. Los resultados son prometedores para la implementación en campo del monitoreo de grietas en estructuras de edificios.</p>				
Albayrak S., Burnaz O.	Estimation of the temperature profiles of reinforced concrete cross sections exposed to standard fires by using artificial neural networks with different topologies	2016	https://www.scopus.com/inward/record.uri?eid=2-s2.0-84938864678&doi=10.1002%2fam.2317&partnerID=40&md5=83010deec6c77d615afb69743f69936e	John Wiley and Sons Ltd
<p>Resumen: El análisis térmico en elementos estructurales puede ser extremadamente complejo, especialmente para materiales que retienen humedad y tienen una baja conductividad térmica. El método más sencillo para definir el perfil de temperatura a través de la sección transversal es al utilizar datos de prueba presentados en tablas o gráficos, que se publican en códigos o guías de diseño. Estos datos tabulados generalmente se basan en condiciones de incendio estándar. El anexo A de TS-EN1992-1-2 proporciona una serie de perfiles de temperatura calculados para losa o paredes de hormigón, vigas y columnas. Pero estos perfiles se proporcionan para dimensiones de sección transversal específicas y duraciones estándar de resistencia al fuego. El objetivo principal de este estudio es estimar los perfiles de temperatura de secciones transversales de vigas y columnas de hormigón armado mediante el uso de redes neuronales artificiales (RNA) con diferentes topologías. Al modelar una RNA, se beneficia de ANN multicapa, que utiliza reglas de aprendizaje supervisado. Durante la etapa de entrenamiento y prueba de ANN, se utilizan los resultados obtenidos de los perfiles de temperatura antes mencionados. Los valores de temperatura se leyeron de las tablas de perfil de temperatura de acuerdo con la duración estándar del fuego, la altura y el ancho de las secciones transversales, y $Coordenadas x$ e y de los puntos por el punto de referencia. Al probar ANN con diferentes topologías en las conclusiones, se evalúan su usabilidad, ventajas y desventajas. Copyright © 2015, John Wiley & Sons, Ltd.</p>				
Yan B., Dai G.-L., Su H.-	A meteorological parameters-based prediction model of vertical temperature gradient of track plate	2014	https://www.scopus.com/inward/record.uri?eid=2-s2.0-84926652173&doi=10.3969%2fj.issn.1000-565X.2014.12.002&partnerID=40&md5=cc14ccff17f1883fd2cbe66c9e642247	South China University of Technology
<p>Resumen: Los métodos tradicionales de análisis de los campos de temperatura de estructuras de hormigón basados en la termodinámica se caracterizan por demasiadas suposiciones y un consumo excesivo de energía en el cálculo, y con estos métodos es difícil obtener valores de los parámetros. Para saber más sobre la distribución del gradiente de temperatura vertical en la placa de vía, se establece una red neuronal artificial multicapa basada en la retropropagación de errores utilizando datos de observación a largo plazo del campo de temperatura de la placa de vía. Luego, los parámetros meteorológicos fáciles de obtener se utilizan como muestras de entrenamiento para predecir el gradiente de temperatura vertical de la placa de vía, y la precisión de la predicción se verifica mediante los datos medidos. Sobre esta base, las influencias de la diferencia de temperatura diaria, se analizan las horas de sol y la velocidad del viento en el gradiente vertical de temperatura de la placa de vía. Los resultados muestran que (1) cuando la red neuronal artificial de una estructura 4-16-1 se establece con la diferencia de temperatura diaria, la velocidad promedio diaria del viento y las horas de sol como muestras de entrenamiento, la red tiene una gran robustez y puede predecir con precisión el gradiente de temperatura vertical de la placa de vía; (2) existe una relación lineal compleja entre cada parámetro meteorológico y la diferencia de temperatura vertical de la placa de vía; (3) en términos generales, cuanto más fuerte es la luz del sol y mayor es la velocidad del viento, y mayor será el gradiente de temperatura vertical de la placa de la pista; y (4) el gradiente de temperatura vertical de la placa de vía de $-2\sim 10^{\circ}\text{C}$ en la región central de China. ©, 2014, Universidad Tecnológica del Sur de China. Todos los derechos reservados.</p>				

Apéndice B. *Enlace de la implementación del código de la RNA, de las 3 capas de entradas (radiación, temperatura ambiente y foto térmica), y la capa de salida (termopar).*

<https://colab.research.google.com/drive/1Z8a3uIYnAE46Ne93Q1pndedupP7ZL7Rm?hl=es>