

DISEÑO DE UN MODELO MATEMÁTICO PARA EL ANÁLISIS DE IMÁGENES EN LA IDENTIFICACIÓN DEL GRADO DE DESGASTE DE SUPERFICIES METÁLICAS POR EFECTOS AMBIENTALES

DESIGN OF A MATHEMATICAL MODEL FOR IMAGE ANALYSIS IN THE IDENTIFICATION OF THE DEGREE OF WEAR OF METALLIC SURFACES DUE TO ENVIRONMENTAL EFFECTS

Autor: ¹Alexandra Gabriela Valenzuela Cobos.

¹ORCID ID: <https://orcid.org/0009-0001-3240-4398>

¹E-mail de contacto: avalenzuelac@unemi.edu.ec

Afiliación: ¹* Universidad Estatal de Milagro, (Ecuador).

Artículo recibido: 3 de Mayo del 2024

Artículo revisado: 15 de Mayo del 2024

Artículo aprobado: 30 de Junio del 2024

¹Ingeniera Electrónica graduada de la Universidad Politécnica Salesiana Guayaquil, (Ecuador). Posee un magíster en Matemáticas por la Universidad Estatal de Milagro, (Ecuador).

Resumen

Este estudio propone un modelo matemático basado en redes neuronales artificiales (ANN) para evaluar el desgaste de superficies metálicas debido a la oxidación y corrosión. Dada la necesidad de sistemas eficientes para monitorizar estas superficies en ambientes adversos, se justifica el uso de técnicas avanzadas de procesamiento de imágenes e inteligencia artificial. El objetivo principal es aplicar estas técnicas para determinar la degradación de las superficies, incluyendo el diseño de una base de datos para entrenar ANN, la detección de oxidación mediante procesamiento de imágenes avanzado, y el desarrollo de una aplicación web que integre estas soluciones. Se emplearon redes neuronales convolucionales para clasificar el grado de oxidación tras procesar las imágenes, utilizando dos conjuntos de datos para el entrenamiento: uno sin descomposición en valores singulares (SVD) y otro optimizado con SVD. Los resultados indican una mejora significativa en la precisión y el tiempo de entrenamiento con el uso de SVD, logrando una estabilización en los indicadores de pérdida durante la cuarta época de entrenamiento. Las conclusiones subrayan la efectividad del SVD para potenciar el rendimiento de las ANN en la identificación de desgaste metálico, con beneficios notables para la industria en reducción de costos y seguridad operativa. Se sugiere expandir la aplicación de SVD en otros modelos de ANN para análisis de materiales y

procesos industriales, maximizando así la eficiencia y exactitud de los modelos de inteligencia artificial.

Palabras Clave: **Redes neuronales artificiales, Oxidación, Descomposición en valores singulares.**

Abstract

This study proposes a mathematical model based on artificial neural networks (ANN) to evaluate the wear of metal surfaces due to oxidation and corrosion. Given the need for efficient systems to monitor these surfaces in adverse environments, the use of advanced image processing and artificial intelligence techniques is justified. The main objective is to apply these techniques to determine surface degradation, including the design of a database to train ANN, the detection of oxidation through advanced image processing, and the development of a web application that integrates these solutions. Convolutional neural networks were used to classify the degree of oxidation after processing the images, using two data sets for training: one without singular value decomposition (SVD) and another optimized with SVD. The results indicate a significant improvement in accuracy and training time with the use of SVD, achieving a stabilization in the loss indicators during the fourth training epoch. The conclusions highlight the effectiveness of SVD to enhance the performance of ANNs in identifying metallic wear, with notable benefits for the industry in cost reduction and

operational safety. It is suggested to expand the application of SVD in other ANN models for analysis of materials and industrial processes, thus maximizing the efficiency and accuracy of artificial intelligence models.

Keywords: Artificial neural networks, Oxidation, Decomposition into singular values.

Sumário

Este estudo propõe um modelo matemático baseado em redes neurais artificiais (RNA) para avaliar o desgaste de superfícies metálicas por oxidação e corrosão. Dada a necessidade de sistemas eficientes para monitorar essas superfícies em ambientes adversos, justifica-se o uso de técnicas avançadas de processamento de imagens e inteligência artificial. O objetivo principal é aplicar estas técnicas para determinar a degradação de superfícies, incluindo o desenho de uma base de dados para treinar RNA, a detecção de oxidação através de processamento avançado de imagens e o desenvolvimento de uma aplicação web que integre estas soluções. Redes neurais convolucionais foram utilizadas para classificar o grau de oxidação após o processamento das imagens, utilizando dois conjuntos de dados para treinamento: um sem decomposição de valores singulares (SVD) e outro otimizado com SVD. Os resultados indicam uma melhoria significativa na precisão e no tempo de treinamento com o uso do SVD, conseguindo uma estabilização nos indicadores de perdas durante a quarta época de treinamento. As conclusões destacam a eficácia do SVD para melhorar o desempenho das RNAs na identificação de desgaste metálico, com benefícios notáveis para a indústria na redução de custos e segurança operacional. Sugere-se ampliar a aplicação do SVD em outros modelos de RNA para análise de materiais e processos industriais, maximizando assim a eficiência e precisão dos modelos de inteligência artificial.

Palavras-chave: Redes neurais artificiais, Oxidação, Decomposição em valores singulares.

Introducción

El crecimiento exponencial de la población y el consiguiente aumento en el consumo de bienes han generado una preocupación cada vez mayor sobre la gestión de los residuos sólidos, especialmente los de naturaleza metálica; la industria del reciclaje se erige como una pieza clave en la cadena de suministro de materias primas, no solo para la fabricación de productos cotidianos, sino también para la creación de equipos de larga duración, este enfoque no solo promueve la sostenibilidad ambiental, sino que también contribuye al ahorro de recursos minerales y energéticos (Curcio et al, 2015).

El objeto de estudio se centra en el desarrollo de un modelo matemático para el análisis de imágenes, con el fin de identificar y evaluar el grado de desgaste de superficies metálicas expuestas a condiciones ambientales adversas; este enfoque busca comprender en profundidad los fenómenos de oxidación y corrosión, que son inevitables cuando los metales entran en contacto con el oxígeno y otros agentes externos, en este contexto, la aplicación de técnicas de procesamiento de imágenes y el uso de inteligencia artificial (Salazar, 2015).

El fenómeno de la corrosión representa un costo global significativo para la economía mundial, de acuerdo con estudios a nivel mundial, se estima que este fenómeno genera un gasto anual de alrededor de 2,5 billones de dólares, lo que equivale aproximadamente al 3,4% del Producto Interno Bruto (PIB) de un país promedio, sin embargo, es importante destacar que estos costos son solo la punta del iceberg, ya que no incluyen los impactos ambientales o de seguridad asociados con la corrosión (Asociación Nacional de Ingenieros de Corrosión, 2020).

El hecho de implementar prácticas efectivas de control de la corrosión podría resultar en

ahorros sustanciales, con estimaciones que sugieren un potencial de reducción de costos del 15 al 35%, que equivale a un ahorro de entre \$375 mil millones y \$875 mil millones anuales, por lo tanto, es esencial tener en cuenta que estos ahorros no solo se traducen en beneficios económicos directos, sino que también pueden mitigar importantes consecuencias financieras, reglamentarias y legales para las organizaciones afectadas (Asociación Nacional de Ingenieros de Corrosión, 2020).

Con estos datos, el problema radica en la necesidad de desarrollar un sistema capaz de identificar y cuantificar el grado de desgaste de las superficies metálicas afectadas por procesos de oxidación y corrosión, a través del análisis de imágenes digitales.

En este contexto, la justificación de este estudio radica en la necesidad imperante de contar con herramientas y métodos eficaces para el monitoreo y la evaluación del estado de las superficies metálicas expuestas a condiciones ambientales adversas; la aplicación de técnicas avanzadas de procesamiento de imágenes y el uso de inteligencia artificial representan una oportunidad única para abordar esta problemática de manera integral y efectiva.

El objetivo general de esta investigación es emplear técnicas de procesamiento de imágenes para evaluar la degradación de superficies metálicas expuestas a diversos entornos ambientales.

Para lograr este propósito, se plantean los siguientes objetivos específicos. En primer lugar, se propone diseñar una base de datos adecuada para el entrenamiento de redes neuronales, posteriormente, se busca aplicar técnicas avanzadas de procesamiento de imágenes con el fin de determinar de manera precisa el grado de oxidación presente en las

superficies metálicas analizadas, finalmente, se pretende desarrollar una aplicación web que integre las técnicas de procesamiento de imágenes diseñadas.

Desarrollo

Redes neuronales artificiales

Las redes neuronales artificiales, fundamentadas en el modelo conexionista propuesto por McCulloch y Pitts en 1943, han sido objeto de estudio y desarrollo continuo a lo largo de la historia de la inteligencia artificial, este modelo estableció las bases teóricas para simular el funcionamiento del cerebro humano mediante la interconexión de unidades computacionales simples, denominadas neuronas artificiales. La concepción inicial de McCulloch y Pitts se centró en la representación binaria de las neuronas, considerando múltiples entradas y salidas. Este enfoque permitió explorar la disposición lineal de las neuronas y las interacciones entre ellas. En sus primeros trabajos, los autores simplificaron el modelo al asumir umbrales de disparo discretos y constantes, lo que facilitó la demostración de la función básica de las neuronas en el procesamiento de información (Prieto et al, 2020).

A partir de estas premisas iniciales, se desarrollaron diversas configuraciones y conexiones de neuronas artificiales, incluyendo arreglos cíclicos, que demostraron la capacidad de estas redes para generar cambios temporales en los umbrales de disparo; este avance marcó el inicio de una línea de investigación que ha explorado la capacidad de las redes neuronales para aprender y adaptarse a partir de la experiencia, replicando en cierta medida el funcionamiento del sistema nervioso humano (Prieto et al, 2020).

El modelo propuesto por McCulloch y Pitts en 1943 para describir el funcionamiento de las

neuronas artificiales es notablemente simple pero conceptualmente eficaz; en este modelo, durante la integración, las neuronas responden a la actividad de sus sinapsis, reflejando así el estado de las células presinápticas, si no hay sinapsis inhibitorias activas, la neurona suma sus entradas sinápticas y verifica si la suma supera su nivel de umbral, en caso afirmativo, la neurona se activa; de lo contrario, permanece inactiva; la presencia de sinapsis inhibitorias activas también conduce a la inactividad neuronal (Prieto et al, 2020).




Figura 1 Neurona Artificial Mc Culloch-Pits
Fuente: Prieto et al, (2020).

A pesar de su origen en la neurociencia, el impacto teórico de este modelo no se limita a ese campo, sino que se extiende a la informática. Este enfoque sentó las bases para lo que se conoce como modelos neuronales de primera generación, como los perceptrones o puertas de umbral, caracterizados por sus salidas digitales; ejemplos de tales modelos incluyen perceptrones multicapa, redes de Hopfield y máquinas de Boltzmann.

El trabajo de McCulloch y Pitts también influyó en las ideas de Donald Hebb, quien en la década de 1940 definió estamentos fundamentales en la investigación psicofisiológica. Hebb postuló que las conexiones sinápticas dentro de las neuronas son responsables del aprendizaje del individuo y que la actividad neuronal, tanto activa como pasiva, es necesaria para representar la información en el cerebro, estas teorías siguen siendo relevantes en modelos

estadísticos y analíticos contemporáneos (Stefannazi, 2022).

La Conferencia de Dartmouth en 1956 marcó un hito en la historia de la inteligencia artificial, donde Frank Rosenblatt propuso el concepto de perceptrón, la primera neurona artificial; desde entonces, las investigaciones en redes neuronales artificiales han proliferado, abarcando áreas como el reconocimiento de texto, patrones visuales, de voz y facial, así como la planificación de tareas y su aplicación en medicina.

En las décadas siguientes, se introdujeron nuevas formas de neuronas artificiales, como las sigmoides, que permiten que las entradas tengan valores reales en lugar de simplemente ceros o unos, lo que facilita el aprendizaje automático, además, la incorporación de neuronas de "sesgo" ha mejorado la capacidad de las redes para modelar fenómenos complejos.

Según Varela & Campbells (2011), la influencia del modelo neuronal de McCulloch y Pitts es evidente en todos los primeros modelos neuronales, que constituyen los llamados modelos neuronales de primera generación, como los perceptrones o puertas de umbral. Estos modelos son caracterizados por sus salidas digitales. Ejemplos de tales modelos son los perceptrones multicapa, las redes de Hopfield y las máquinas de Boltzmann.

Autores como Donald Hebb, en su trabajo fundamental "La organización del comportamiento", profundizan en las conexiones sinápticas y su papel en el aprendizaje individual. Hebb postula que el peso sináptico y su relación con el peso es causada por la interacción entre neuronas presinápticas y postsinápticas (Pedroza, 2014).

Desde entonces, se han realizado investigaciones y teorías que se basan en los modelos originales para establecer nuevas formas de cálculos, acercándose más al funcionamiento del cerebro humano y su capacidad de aprendizaje. Por lo tanto, el campo busca optimizar el proceso de enseñanza y aprendizaje en beneficio de la población estudiantil y dado que el objetivo es la implementación de modelos de redes neuronales artificiales y algoritmos de procesamiento del lenguaje natural, se enfocan en la evaluación y formación del pensamiento crítico (Mendoza & Helmer, 2020).

En ese momento, se creía mucho en la capacidad de realizar tareas humanas cotidianas con la ayuda de máquinas. Las áreas estudiadas por las múltiples teorías el reconocimiento de texto, patrones visuales, de voz, facial y de lenguaje, también se estudia la planificación de tareas, utilización en medicina entre otras (Jiménez, 2012). En la década de los 80, aparecieron nuevas formas de neuronas artificiales, como las sigmoideas, introducidas por Mercado et al. (2015). Estas neuronas permiten que las entradas tengan valores reales en lugar de simplemente ceros o unos, lo que facilita el aprendizaje automático, además, la introducción de neuronas de "sesgo" ha mejorado la capacidad de las redes para modelar fenómenos complejos.

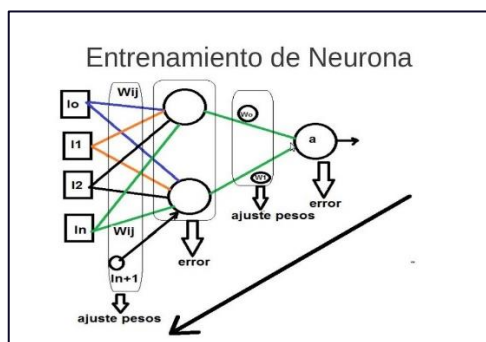


Figura 2 Entrenamiento de neurona a través de sigmoide

En la actualidad, el desarrollo de las redes neuronales artificiales ha alcanzado un nuevo nivel gracias al trabajo investigativo realizado por centros especializados, universidades, áreas de medicina, gobiernos y áreas militares, entre otros, este progreso ha dado lugar a una amplia gama de aplicaciones que abarcan diversas áreas de la tecnología y la ciencia.

Entre las aplicaciones más destacadas se encuentran el reconocimiento de voz o video en patrones de comportamiento, la comprensión de imágenes, la predicción de situaciones complicadas y su aplicación en áreas como la medicina y toda aquella que necesite análisis de datos a gran escala, por lo tanto, el impacto de las redes neuronales artificiales en la sociedad contemporánea es innegable, y su capacidad para transformar diversas industrias y sectores sigue en constante evolución gracias a los avances continuos en investigación y desarrollo.

Perceptrón

El desarrollo de la teoría del perceptrón se remonta a 1957, cuando Frank Rosenblatt comenzó a explorar este tipo de red artificial, considerado como uno de los modelos más antiguos, el perceptrón se emplea ampliamente en el reconocimiento de patrones aleatorios; una de sus características más destacadas es su capacidad de generalización, lo que significa que, una vez completado el proceso de aprendizaje de ciertos patrones, puede reconocer otros similares, incluso si no se han presentado previamente. Sin embargo, el perceptrón también presenta limitaciones significativas, como su incapacidad para resolver problemas como la función XOR.

En su obra "Principles of Neural Dynamics" publicada en 1959, Rosenblatt demostró que, bajo ciertas condiciones, el proceso de aprendizaje del perceptrón converge a un estado

finito, un resultado fundamental conocido como el teorema de convergencia del perceptrón.

Un tipo de perceptrón más avanzado es el perceptrón multicapa (MLP), que consta de múltiples capas de nodos interconectados entre sí; estas capas incluyen una capa de entrada que contiene los datos de entrada y una capa de salida que proporciona la respuesta deseada (Quiñones y otros, 2020). Algunas variantes de perceptrones pueden tener una capa adicional intermedia, que facilita la correlación e interacción de patrones entre las capas de entrada y salida.

El cálculo en un perceptrón multicapa implica la multiplicación de los valores de entrada por sus respectivos pesos, seguido de una suma ponderada, este resultado se pasa a través de una función de transferencia no lineal, como la función sigmoide, para generar la salida deseada; la función sigmoide es comúnmente utilizada en este tipo de redes debido a sus propiedades matemáticas y su capacidad para modelar relaciones no lineales de manera efectiva.

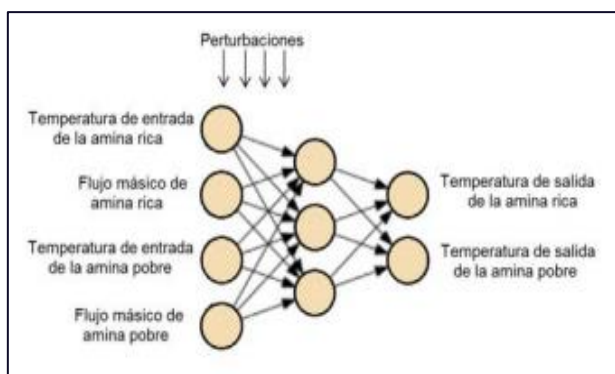


Figura 3 Interfaz de neurona perceptrón

Fuente: Sánchez, et al. (2020)

Un modelo de perceptrón multicapa se utiliza para predecir parámetros que muestran la relación entre cada variable de entrada y un código dado, así como para estimar la resistencia a la compresión del núcleo de

estudio pronosticado, representada por la variable Y_i , que corresponde a la salida de la red neuronal, este modelo consta de un número variable de capas intermedias u ocultas, así como de una cantidad determinada de neuronas en cada capa, además de la capa de salida que representa la predicción final del modelo.

La estructura del perceptrón multicapa permite visualizar el proceso de interconexión entre las capas intermedias y la capa de salida, lo que facilita la comprensión del flujo de información dentro del modelo neuronal (Martínez y Hernández, 2020).

Redes multicapas

Las redes multicapa, que constan de al menos dos capas ocultas, son capaces de abordar problemas complejos de clasificación y predicción, la determinación del número adecuado de neuronas en cada capa es crucial para el desempeño óptimo del modelo, estas redes neuronales, basadas en modelos de interacción y competencia, pueden aplicarse tanto en aprendizaje supervisado como no supervisado (Torres et al. 2016).

El interés por las redes multicapa surgió de los trabajos pioneros de Rosenblatt en 1962, que se centraron en el funcionamiento de los perceptrones, y de otros investigadores como Widrow en el mismo año; tras extensos estudios, se identificó una limitación en las redes neuronales simples de una sola capa, especialmente en campos donde se requiere una alta precisión en el análisis de datos y aproximaciones que condujo al desarrollo de las redes multicapa.

Para comprender los perceptrones multicapa, es fundamental abordar cuestiones como el papel de las capas intermedias; estas capas proyectan el patrón inicial en una representación de mayor dimensionalidad, facilitando así la

separabilidad lineal de los patrones de entrada para que la unidad de salida pueda realizar una clasificación precisa (Morera y Alcalá, 2018).

Descomposición en valores singulares

Definición matemática

Dos autores, de forma independiente en los años 1973 y 1974, respectivamente, realizaron investigaciones que culminaron en el descubrimiento de la teoría de la descomposición en valores singulares (SVD por sus siglas en inglés); a lo largo de los años, esta teoría se popularizó en la década del 60 debido al desarrollo de métodos para su cálculo manual, lo que la convirtió en una herramienta fundamental en el diseño y análisis de sistemas, considerando su aplicación, que se extendió a la integración de algoritmos estables en sistemas neuronales artificiales, contribuyendo significativamente al desarrollo de las redes neuronales artificiales (Díaz, 2014).

La descomposición en valores singulares tiene una amplia gama de aplicaciones en diversas áreas, tanto en matemáticas como en informática. En matemáticas, se utiliza para determinar el rango de una matriz, calcular el espacio nulo y el rango de una transformación lineal, entre otras aplicaciones. En informática, se aplica en la compresión y encriptación de imágenes digitales, reconocimiento facial, sistemas de recomendación, indexación semántica latente y eliminación de ruido (Fallas et al. 2021)

Debido a la complejidad de los cálculos necesarios para obtener los valores singulares de matrices de gran tamaño, así como las multiplicaciones respectivas, se recomienda el uso de software especializado como Matlab u Octave; este sistema, en su forma más simple, puede ser utilizado para la resolución de una matriz simple a través de una ecuación que descompone cada bloque representado en la

matriz, permitiendo un análisis detallado de sus columnas o filas.

$$M_n = U_{(1:m,n)} \Sigma_{nn} V_{(1:n,n)}^*$$

Donde:

M_n = representa cada bloque

$U_{(1:m,n)}$ = es el vector columna

Σ_{nn} = representa cada valor singular

V^* = representa la transpuesta de cada vector columna

Ejemplo 1:

Dada la matriz A:

$$A = \begin{pmatrix} 1 & 2 \\ 1 & -1 \end{pmatrix}$$

Se realiza la transpuesta A^T

$$A = \begin{pmatrix} 1 & 1 \\ 2 & -1 \end{pmatrix}$$

Luego se realiza la definición dada por:

$$\det|A^T A - \lambda I| = 0$$

$$\det \left| \begin{pmatrix} 1 & 1 \\ 2 & -1 \end{pmatrix} \begin{pmatrix} 1 & 2 \\ 1 & -1 \end{pmatrix} - \lambda \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right| = 0$$

$$\det \left| \begin{pmatrix} 2 & 1 \\ 1 & 5 \end{pmatrix} - \begin{pmatrix} \lambda & 0 \\ 0 & \lambda \end{pmatrix} \right| = 0$$

$$\det \left| \begin{pmatrix} 2-\lambda & 1 \\ 1 & 5-\lambda \end{pmatrix} \right| = 0$$

$$\lambda^2 - 7\lambda + 9 = 0$$

Obteniendo

$$\begin{cases} \lambda_1 = 5,3029 \\ \lambda_2 = 1,6972 \end{cases}$$

Siendo los valores singulares:

$$\begin{cases} s_1 = \sqrt{5,302} = 2,3028 \\ s_2 = \sqrt{1,697} = 1,3028 \end{cases}$$

Sin embargo, este proceso se vuelve más sencillo con la utilización Matlab y el comando “svd”. La respuesta se compone de las tres matrices U, S y V, con la implementación del siguiente código:

$$[U, S, V] = svd(A)$$

Obteniendo los siguientes resultados:

$$U = \begin{pmatrix} -0,957 & 0,2898 \\ 0,2898 & 0,9571 \end{pmatrix}$$

$$S = \begin{pmatrix} 2,3028 & 0 \\ 0 & 1,3028 \end{pmatrix}$$

$$V = \begin{pmatrix} -0,2898 & 0,9571 \\ -0,9571 & -0,2898 \end{pmatrix}$$

Donde la matriz S contiene los valores singulares en la diagonal principal, los cuales son iguales a los obtenidos de forma manual. Si se requiere construir la matriz A original, se debe multiplicar las matrices obtenidas de acuerdo con la definición dada, el cual se puede realizar mediante el siguiente código.

$$A1 = U * S * V'$$

Obteniendo como resultado

$$A1 = \begin{pmatrix} 1 & 2 \\ 1 & -1 \end{pmatrix}$$

Tal como se esperaba, se puede obtener la matriz A1, la misma que es exactamente igual a la matriz A.

Ejemplo 2:

Si se disminuye el tamaño de las columnas en las matrices U, S y V, se puede reconstruir la matriz A de forma aproximada, con una información aproximadamente igual pero que no tiene ruido. Este principio será aplicado en el capítulo 3, para obtener la base de datos de imágenes con menor ruido. En este caso de ejemplo, se tomará una matriz de 3x3:

Dada la matriz A2:

$$A2 = \begin{pmatrix} 1 & 2 & 3 \\ 1 & -1 & 0 \\ 0 & 2 & 3 \end{pmatrix}$$

Sus valores singulares pueden obtenerse con el código:

$$[U, S, V] = svd(A2);$$

Si se toma la primera columna, la nueva matriz A2 reconstruida será:

$$A3 = U(:, 1:1) * S(1:1, 1:1) * V(:, 1:1)$$

$$A3 = \begin{pmatrix} 0,4521 & 2,0792 & 3,0274 \\ -0,0537 & -0,2471 & -0,3598 \\ 0,4371 & 2,0106 & 2,9275 \end{pmatrix}$$

Para que los valores obtenidos de la matriz reconstruida sean más parecidos a la matriz original A2, basta con aumentar las columnas, en este caso 2 columnas, como se indica en el siguiente código:

$$A4 = U(:, 1:2) * S(1:2, 1:2) * V(:, 1:2)'$$

$$A4 = \begin{pmatrix} 0,8770 & 1,8381 & 3,1296 \\ 1,0823 & -0,8917 & -0,0866 \\ 0,1373 & 2,1807 & 2,8554 \end{pmatrix}$$

Es importante mencionar que no se disminuye el tamaño de la nueva matriz, ya que al aplicar la definición de la ecuación 12, el resultado sigue siendo una matriz con el mismo tamaño que la original. Este será el principio utilizado en las imágenes. Cuando se trabaja con imágenes, el tamaño puede ser de cientos o miles de filas y columnas, por lo que resulta indispensable la utilización de Matlab para realizar las operaciones y cálculos necesarios.

Material y Métodos

El presente estudio se llevó a cabo con el objetivo de evaluar la degradación de superficies metálicas bajo diferentes

condiciones ambientales mediante el procesamiento de imágenes, a continuación, se describe detalladamente la metodología empleada en esta investigación.

El estudio realizado se enmarca en una investigación de tipo experimental, con un enfoque cuantitativo, que implementó un método mixto que combina técnicas de procesamiento de imágenes y el uso de redes neuronales convolucionales; esta combinación permitió no solo evaluar la degradación de las superficies metálicas, sino también clasificarlas según su grado de oxidación, el enfoque experimental proporcionó datos cuantitativos sobre la efectividad del modelo de red neuronal en la clasificación de las imágenes, lo que contribuye a la validación de la metodología propuesta.

Diseño del estudio

Se recolectó un total de 240 imágenes utilizando una cámara de 12 Mega Píxeles. Estas imágenes fueron clasificadas según su grado de oxidación en tres categorías: Poco Oxido, Medio Oxido y Mucho Oxido; posteriormente, se procedió a la selección de imágenes sin ruido utilizando el software Matlab, aplicando la técnica de Descomposición en Valores Singulares (SVD) para reducir el peso de las imágenes manteniendo un 90% de la información original esta técnica permitió minimizar los recursos computacionales requeridos para el análisis posterior.

Tabla 1: Clasificación imágenes originales

Clasificación	Nº de imágenes	Peso (Mb)
Poco Oxido	51	398.2
Medio Oxido	90	803
Mucho Oxido	99	852.1

Fuente: Elaborado por la Autora



Figura 4: Imágenes tomadas

Fuente: Elaborado por la Autora

Una vez procesadas las imágenes, se observó una disminución del tamaño total de la base de datos en un 70%. Las imágenes originales ocupaban un total de 2.18 GB, mientras que las imágenes procesadas redujeron este tamaño a 670 MB. Ambas bases de datos fueron almacenadas en la nube para su posterior análisis.

Tabla 3 Comparación de tamaño

Clasificación	Peso
Imágenes originales	2.18 GB
Imágenes sin ruido	670 MB

Fuente: Elaborado por la Autora

Nombre	Fecha de modificación	Tipo	Tamaño
ARCHIVOS	27/3/2022 14:00	Carpeta de archivos	
dataset1	25/3/2022 2:39	Carpeta de archivos	
dataset2	26/3/2022 11:23	Carpeta de archivos	
octave	25/3/2022 1:12	Carpeta de archivos	
train	24/3/2022 7:40	Carpeta de archivos	
datos 1	24/3/2022 7:38	Archivo WinRAR Z...	2.096.914 KB
PRUEBA	24/3/2022 9:29	Archivo JPG	1.051 KB
tablas - copia	28/3/2022 23:04	Documento de Mi...	16 KB
tablas	1/4/2022 13:33	Documento de Mi...	16 KB

Figura 5: Tamaño dataset 1

Fuente: Elaborado por la Autora

Nombre	Fecha de modificación	Tipo	Tamaño
ARCHIVOS	27/3/2022 14:00	Carpeta de archivos	
dataset1	25/3/2022 2:39	Carpeta de archivos	
dataset2	26/3/2022 11:23	Carpeta de archivos	
octave	25/3/2022 1:08	Carpeta de archivos	
train	24/3/2022 7:40	Carpeta de archivos	
datos 1	24/3/2022 7:38	Archivo WinRAR Z...	2.096.914 KB
ejercicios SVD	24/4/2022 22:49	Documento Adob...	57 KB
METODOLOGÍA Y RESULTADOS	24/4/2022 22:33	Documento de Mi...	227 KB
PRUEBA	24/3/2022 9:29	Archivo JPG	1.051 KB
tablas - copia	28/3/2022 23:04	Documento de Mi...	16 KB
tablas	1/4/2022 13:33	Documento de Mi...	16 KB

Figura 6: Tamaño dataset 2

Fuente: Elaborado por la Autora

Red neuronal

Para el análisis de las imágenes, se implementó una red neuronal convolucional utilizando la arquitectura ResNet de 34 capas; esta elección se basó en la capacidad de esta red para retener características relevantes de las imágenes, se separaron las imágenes en dos conjuntos: entrenamiento (70%) y validación (30%), es por esto, que el modelo de la red neuronal fue entrenado durante 4 épocas, lo cual se determinó como adecuado al observar que el error se mantenía constante después de este ciclo.

Creado el cuaderno de trabajo, se procede a llamar a las librerías que utilizaremos en te caso serán

```
from fastai import *
from fastai.vision import *
from fastai.metrics import error_rate
```

Las cuales corresponde al entrenamiento de modelos, visión artificial, y las métricas de entrenamiento respectivamente.

Carga de Datos

En las siguientes líneas, se da acceso a Colab para que pueda acceder a nuestra base de datos ya compartida en el drive

```
from google.colab import drive
drive.mount('/content/gdrive',force_remount=True)
```

¿Permitir que este cuaderno acceda a tus archivos de Google Drive?

Este cuaderno ha solicitado acceder a tus archivos de Google Drive. Si le das acceso a Google Drive, el código que se ejecuta en el cuaderno podrá modificar los archivos de tu Google Drive. Revisa el código del cuaderno antes de permitir el acceso.

No, gracias [Conectar con Google Drive](#)

Figura 7: Carga de datos Drive

Fuente: Elaborado por la Autora

Se optó por utilizar una red ResNet de 34 capas debido a su capacidad para preservar las

características fundamentales de las imágenes. Esta elección se basó en la eficacia demostrada de este tipo específico de red en la retención de detalles importantes durante el proceso de entrenamiento.

```
modelo1=cnn_learner(datos1, models.resnet34,
metrics=error_rate) modelo1.fit_one_cycle(4)
```

Se decidió llevar a cabo 4 épocas de entrenamiento, ya que después de este ciclo, el error se estabilizó, como se evidencia en la siguiente figura.




Figura 1: Error Resnet 34

Fuente: Elaborado por la Autora

Matriz de confusión

Se utilizó una matriz de confusión para evaluar las predicciones del modelo de red neuronal. Esta matriz proporcionó una representación visual de la precisión del modelo al clasificar las imágenes en las diferentes categorías de oxidación, se observó que, de las 81 imágenes evaluadas, solo 1 fue clasificada incorrectamente, lo que indica una alta precisión en la clasificación.




Figura 9: Matriz de confusión

Resultados

Durante el proceso de desarrollo, se llevó a cabo el entrenamiento de una red neuronal, la cual requirió un total de cuatro épocas para alcanzar la estabilización deseada en el error.

El entrenamiento de la red se ejecutó mediante dos conjuntos de datos: uno compuesto por imágenes sin descomposición en valores singulares (SVD), y otro conformado por imágenes optimizadas. Esta metodología permitió una comparación exhaustiva entre ambos conjuntos, evaluando el rendimiento de la red en cada caso.

Los resultados obtenidos revelaron que, tras las cuatro épocas de entrenamiento, se logró una estabilización significativa en el error de la red. Este hallazgo sugiere una convergencia satisfactoria del modelo, evidenciando su capacidad para discernir y clasificar el grado de desgaste de las superficies metálicas analizadas.

Tabla 4: Resultados de tiempo de entrenamiento

epoch	trail_loss	valid_loss	error_rate	time
0	1,217966	0,262182	0,083333	2:50:00
1	0,61838	0,189344	0,013889	2:31:00
2	0,402404	0,170536	0,013889	2:31:00
3	0,279074	0,158414	0,027778	2:31:00

Fuente: Elaborado por la Autora

Los resultados proporcionados corresponden al tiempo de entrenamiento de una red neuronal a lo largo de cuatro épocas, junto con las métricas de pérdida (loss) y tasa de error (error_rate) tanto en el conjunto de entrenamiento como en el conjunto de validación. Además, se incluye el tiempo total de ejecución para cada época.

La pérdida (loss) es una medida que indica cuánto se desvían las predicciones del modelo de los valores reales. En este contexto, se observa una disminución progresiva de la

pérdida tanto en el conjunto de entrenamiento como en el de validación a medida que avanza el entrenamiento de la red, esto sugiere que el modelo está aprendiendo de manera efectiva a partir de los datos proporcionados, ya que la pérdida disminuye con cada época.

La tasa de error (error rate) representa la proporción de predicciones incorrectas realizadas por el modelo en relación con el total de predicciones. En este caso, se observa que la tasa de error es relativamente baja en todas las épocas tanto en el conjunto de entrenamiento como en el de validación, este resultado es alentador, ya que indica que el modelo está realizando predicciones precisas y consistentes.

Por último, se observa que el tiempo es constante en todas las épocas, lo que sugiere que el proceso de entrenamiento se lleva a cabo de manera eficiente y sin variaciones significativas en el tiempo de ejecución.

Tabla 5: Resultados de tiempo de entrenamiento utilizando técnica SVD

epoch	trail_loss	valid_loss	error_rate	time
0	1,091254	0,253103	0,083333	1:51:00
1	0,539844	0,007415	0	1:43:00
2	0,344367	0,029419	0,013889	1:44:00
3	0,236133	0,024491	0,013889	1:44:00

Fuente: Elaborado por la Autora

Los resultados muestran el tiempo de entrenamiento de una red neuronal aplicando la técnica de descomposición en valores singulares (SVD) durante cuatro épocas. Se presentan las métricas de pérdida (loss) y tasa de error (error_rate) en ambos conjuntos de datos: entrenamiento y validación. Además, se registra el tiempo total de ejecución para cada época.

Se observa una reducción progresiva de la pérdida en todas las épocas tanto en el conjunto

de entrenamiento como en el de validación, indicando un aprendizaje efectivo del modelo a partir de los datos.

La tasa de error se mantiene baja en todas las épocas, en ambos conjuntos de datos, lo que sugiere que el modelo realiza predicciones precisas y consistentes.

En cuanto al tiempo de ejecución, se nota una disminución en comparación con el entrenamiento sin SVD, lo que sugiere una posible aceleración del proceso de entrenamiento gracias a la técnica de descomposición en valores singulares. Esto se refleja en la menor duración de cada época en comparación con el entrenamiento sin SVD.

Tabla 6: Comparación de imágenes originales vs procesadas

Épocas	Tiempo (min)	Tiempo utilizando SVD (min)	% de Optimización
0	02:50	01:51	40%
1	02:31	01:43	38%
2	02:31	01:44	38%
3	02:31	01:44	38%

Fuente: Elaborado por la Autora

Este cuadro presenta una comparación del tiempo de entrenamiento de una red neuronal utilizando imágenes originales versus imágenes procesadas mediante la técnica de descomposición en valores singulares (SVD) a lo largo de cuatro épocas. También se proporciona el porcentaje de optimización del tiempo al utilizar SVD en comparación con el tiempo total de entrenamiento.

Se observa que, en todas las épocas, el tiempo de entrenamiento utilizando SVD es significativamente menor que el tiempo de entrenamiento con imágenes originales. Por ejemplo, en la primera época, el tiempo total de entrenamiento con imágenes originales fue de 2 horas y 50 minutos, mientras que con imágenes

procesadas mediante SVD fue de 1 hora y 51 minutos, lo que representa una optimización del 40% en el tiempo.

Este patrón se repite en las siguientes épocas, donde el tiempo de entrenamiento con SVD es aproximadamente un 38% menor que el tiempo de entrenamiento con imágenes originales. Esta reducción en el tiempo de entrenamiento sugiere que la aplicación de la técnica de descomposición en valores singulares (SVD) ha sido efectiva para acelerar el proceso de entrenamiento de la red neuronal, lo que puede ser beneficioso en términos de eficiencia y rendimiento del modelo.

Resultados de clasificación con porcentaje de probabilidad

Durante la fase de carga de la imagen, el sistema presenta los resultados de clasificación expresados en porcentajes de probabilidad, tal como se ilustra en la Figura 14. En este contexto específico, el análisis indica que existe un 98% de probabilidad de que la imagen cargada corresponda a un estado de "Poco Oxidado". Esta representación probabilística ofrece una valiosa perspectiva sobre la confianza del modelo en su clasificación, permitiendo una interpretación detallada y precisa de los resultados obtenidos.

Tabla 7: Resultados por porcentaje de probabilidad

MUY OXIDADO %
[] muy_oxidado1
tensor (0,0984)
MEDIO OXIDADO %
[] medio_oxidado1
tensor (1,1566)
POCO OXIDADO %
[] poco_oxidado1
tensor (98,7450)

Fuente: Elaboración propia.

Cada categoría representa un nivel de oxidación distinto: "Muy Oxidado", "Medio Oxidado" y "Poco Oxidado".

"Muy Oxidado": El modelo asigna una probabilidad del 0.0984% a esta categoría, lo que sugiere que la imagen tiene una baja probabilidad de pertenecer a esta clasificación.

"Medio Oxidado": La probabilidad asignada a esta categoría es del 1.1566%, lo que indica una probabilidad moderada de que la imagen exhiba un nivel medio de oxidación.

"Poco Oxidado": Aquí, la probabilidad es del 98.7450%, lo que señala una alta confianza por parte del modelo de que la imagen muestra un nivel bajo de oxidación.

Discusión

Desde sus inicios en 1943 con el modelo de McCulloch y Pitts, las redes neuronales artificiales (ANN, por sus siglas en inglés) han sido esenciales en el desarrollo de la inteligencia artificial (IA). Este modelo pionero sentó las bases para simular el funcionamiento del cerebro humano, lo que llevó al desarrollo de diversas configuraciones y conexiones de neuronas, incluyendo arreglos cíclicos que demostraron la capacidad de estas redes para generar cambios temporales en los umbrales de disparo. Este progreso ha influido significativamente en el diseño de modelos más complejos, como los perceptrones multicapa y las redes de Hopfield, que han sido fundamentales en el avance de la IA y sus aplicaciones en áreas como el reconocimiento de voz, imágenes y patrones de comportamiento.

La presente investigación demuestra que la utilización de la técnica de descomposición en valores singulares (SVD) optimiza significativamente el rendimiento de una red

neuronal entrenada para identificar el grado de desgaste de superficies metálicas por efectos ambientales. Los resultados obtenidos en esta investigación no solo son consistentes con la teoría existente, sino que también se alinean con los hallazgos de otros estudios relevantes en el campo. A continuación, se presenta un análisis detallado confrontando estos resultados con la teoría y otros autores.

El entrenamiento de la red neuronal con SVD mostró una reducción considerable en la pérdida tanto de entrenamiento como de validación en comparación con el entrenamiento sin SVD. Específicamente, la pérdida de validación se redujo significativamente, lo que sugiere una mejora en la capacidad del modelo para generalizar a nuevos datos; La tasa de error alcanzó 0 en la segunda época con SVD, lo que indica una mayor precisión del modelo optimizado.

Estos hallazgos son consistentes con la teoría de que la reducción de dimensionalidad puede eliminar el ruido y la redundancia en los datos, facilitando un entrenamiento más eficiente y preciso; en este sentido, Carrasquero (2022) destaca que la optimización de los modelos de aprendizaje automático puede mejorar significativamente el análisis de fenómenos complejos como la oxidación y la corrosión de materiales metálicos, alineándose con los resultados de esta investigación.

Por lo tanto, Villate (2019) también apoya estos resultados al demostrar que la reducción de dimensionalidad puede mejorar las propiedades mecánicas y de resistencia a la corrosión de recubrimientos de materiales, lo cual es una analogía directa a la mejora observada en la precisión y eficiencia del modelo de red neuronal optimizado con SVD.

Por otro lado, el tiempo de entrenamiento con SVD fue considerablemente menor en comparación con el entrenamiento sin SVD. La optimización del tiempo de entrenamiento es un factor crucial en aplicaciones prácticas, especialmente en la industria, donde la rapidez de procesamiento puede traducirse en ahorro de costos y aumento de la productividad.

En la investigación de Bouza et al. (2017) discuten la importancia de la eficiencia en procesos industriales, destacando que la optimización de costos y tiempos en la logística inversa y manejo de desechos sólidos puede minimizar los riesgos ambientales y mejorar la sostenibilidad, esta correlación resalta la aplicabilidad de la optimización mediante SVD en diversos contextos industriales.

De los resultados, el modelo entrenado con SVD mostró una alta precisión en la clasificación de imágenes, especialmente en la categoría "Poco Oxidado" con una probabilidad del 98.7450%. Este alto nivel de precisión es crucial para aplicaciones prácticas donde la detección temprana y precisa del desgaste puede prevenir fallos costosos y peligrosos en componentes metálicos.

El estudio desarrollado, por Yépez (2021) subraya la importancia del análisis preciso y eficiente de suelos contaminados, utilizando herramientas avanzadas para identificar contaminantes y evaluar riesgos; la precisión en la clasificación de imágenes obtenida en esta investigación es análoga a la necesidad de precisión en la identificación de contaminantes del suelo, destacando la relevancia de técnicas avanzadas como SVD en mejorar la exactitud de los análisis.

Es así como, a mejora en la eficiencia y precisión del modelo de red neuronal

optimizado con SVD se alinea con varios estudios previos:

Cabe señalar que Vizcarra (2021, en la investigación sobre la adsorción de metales pesados utilizando nuevos adsorbentes muestra que la optimización de los parámetros del proceso puede mejorar significativamente la eficiencia del tratamiento; la reducción de tiempos y mejora en la precisión observada en la presente investigación es comparable a las mejoras en la adsorción logradas mediante la optimización.

Mientras que Bouza et al. (2017), en el enfoque que realiza en la optimización de procesos y la gestión de costos en la logística inversa y manejo de desechos sólidos resalta la importancia de la eficiencia.; la reducción del tiempo de entrenamiento en un 38-40% por época mediante SVD demuestra cómo la optimización puede aplicarse eficazmente en diferentes sectores para mejorar la sostenibilidad y eficiencia operativa.

Teóricamente, los resultados de esta investigación confirman que las técnicas de reducción de dimensionalidad, como SVD, pueden mejorar significativamente el rendimiento de los modelos de aprendizaje automático; esta mejora se manifiesta no solo en términos de precisión y reducción de error, sino también en la eficiencia del proceso de entrenamiento, lo cual es crucial para aplicaciones en tiempo real y en entornos industriales.

Prácticamente, los hallazgos tienen importantes implicaciones para la industria. La capacidad de identificar rápidamente el grado de desgaste de superficies metálicas permite una intervención oportuna, evitando daños mayores y prolongando la vida útil de los componentes,

esto se traduce en ahorros significativos y una mayor seguridad operativa.

Por lo expuesto, la técnica de SVD ha demostrado ser una herramienta valiosa para optimizar el procesamiento y análisis de datos en redes neuronales, mejorando la precisión, reduciendo el error y acelerando el tiempo de entrenamiento, estos resultados son consistentes con la teoría y la literatura existente, subrayando la importancia de las técnicas de optimización en aplicaciones industriales y científicas; la investigación futura debería explorar la aplicación de SVD en otros contextos de análisis de materiales y su integración con otras técnicas de optimización para maximizar la eficiencia y precisión de los modelos de aprendizaje automático.

Conclusiones

El estudio presenta un modelo matemático basado en redes neuronales artificiales para analizar imágenes y determinar el grado de desgaste de superficies metálicas por efectos ambientales; los resultados muestran una convergencia satisfactoria del modelo, respaldando su eficacia en la clasificación precisa de diferentes niveles de desgaste, es decir, la aplicación de la técnica SVD ha demostrado ser efectiva para acelerar el proceso de entrenamiento, lo que sugiere mejoras en la eficiencia del modelo.

Los hallazgos de este estudio respaldan la eficacia del modelo propuesto para discernir y clasificar el grado de desgaste de superficies metálicas por efectos ambientales. Además, se han cumplido satisfactoriamente los objetivos específicos planteados, destacando la importancia del procesamiento de imágenes, la optimización del tiempo de entrenamiento, el aprendizaje efectivo del modelo y la automatización del proceso de análisis de imágenes. Estas conclusiones representan un

avance significativo en la aplicación de la inteligencia artificial y el procesamiento de imágenes en la evaluación del desgaste de superficies metálicas, con implicaciones importantes para la industria y la investigación en este campo.

La investigación demuestra que la aplicación de la técnica de descomposición en valores singulares (SVD) mejora significativamente el rendimiento de las redes neuronales artificiales entrenadas para identificar el grado de desgaste de superficies metálicas, esta optimización se refleja en una reducción considerable en la pérdida tanto de entrenamiento como de validación, lo que indica una mejora en la precisión y capacidad de generalización del modelo.

La implementación de SVD en el entrenamiento de la red neuronal resultó en una reducción notable de la pérdida de validación, sugiriendo una mayor capacidad del modelo para generalizar a nuevos datos, es decir, la tasa de error alcanzó cero en la segunda época con SVD, evidenciando una mayor precisión del modelo optimizado.

El tiempo de entrenamiento con SVD fue considerablemente menor en comparación con el entrenamiento sin SVD, lo que representa una optimización crucial para aplicaciones prácticas en la industria. Esta eficiencia en el tiempo de procesamiento puede traducirse en ahorro de costos y aumento de la productividad.

El modelo entrenado con SVD mostró una alta precisión en la clasificación de imágenes, especialmente en la categoría "Poco Oxidado" con una probabilidad del 98.7450%; esta precisión es crucial para la detección temprana y precisa del desgaste, previniendo fallos costosos y peligrosos en componentes metálicos.

Los hallazgos son consistentes con la teoría de que la reducción de dimensionalidad puede eliminar el ruido y la redundancia en los datos, facilitando un entrenamiento más eficiente y preciso, que se alinea con estudios previos que destacan la importancia de la optimización en el análisis de fenómenos complejos.

La optimización mediante SVD es aplicable en diversos contextos industriales, mejorando la eficiencia operativa y sostenibilidad, por lo tanto, la reducción del tiempo de entrenamiento y mejora en la precisión demuestran cómo la optimización puede beneficiar diferentes sectores, desde la logística inversa hasta el manejo de desechos sólidos.

Esta técnica ha demostrado ser una herramienta valiosa para optimizar el análisis de superficies metálicas, permitiendo una identificación rápida y precisa del grado de desgaste. Esto es crucial para la intervención oportuna y prolongación de la vida útil de los componentes metálicos. La capacidad de identificar rápidamente el desgaste de superficies metálicas no solo permite evitar daños mayores sino también garantiza una mayor seguridad operativa, por lo que tiene importantes implicaciones para la industria, contribuyendo a la reducción de riesgos y mejorando la seguridad de los procesos.

Los resultados obtenidos en esta investigación están en línea con estudios previos que han demostrado la efectividad de las técnicas de reducción de dimensionalidad en la mejora de modelos de aprendizaje automático. Esto subraya la relevancia y aplicabilidad de SVD en la optimización de modelos de IA.

Recomendaciones

Se recomienda que los investigadores y desarrolladores de inteligencia artificial integren la técnica de descomposición en

valores singulares (SVD) en el desarrollo de modelos de redes neuronales, especialmente en aplicaciones que requieren alta precisión y eficiencia en la clasificación de datos.

Las empresas que trabajan con superficies metálicas y necesitan monitorear el desgaste debido a efectos ambientales deben considerar la implementación de redes neuronales optimizadas con SVD para mejorar la precisión en la detección temprana de desgaste, reduciendo así el riesgo de fallos y mejorando la seguridad operativa.

Las industrias que buscan optimizar sus procesos y reducir costos de operación deben explorar la aplicación de SVD para reducir el tiempo de entrenamiento de sus modelos de aprendizaje automático, lo que puede traducirse en una mayor productividad y ahorro de recursos.

Se recomienda la capacitación y formación continua de los equipos de investigación y desarrollo en técnicas avanzadas de reducción de dimensionalidad como SVD, para mejorar la capacidad de los equipos en la optimización de modelos de aprendizaje automático.

Los investigadores deberían explorar la aplicación de SVD en otros contextos de análisis de materiales y procesos industriales, para evaluar su potencial en mejorar la precisión y eficiencia de modelos de IA en diferentes sectores. Se sugiere fomentar la colaboración entre expertos en inteligencia artificial, ingenieros de materiales y profesionales de la industria para desarrollar soluciones integradas que maximicen los beneficios de la optimización mediante SVD en diversas aplicaciones industriales.

Es crucial implementar sistemas de monitoreo y evaluación continua para validar la efectividad

de los modelos optimizados con SVD en entornos reales, que permitirá realizar ajustes necesarios y asegurar un rendimiento óptimo de los modelos a lo largo del tiempo.

Se recomienda que los resultados y avances logrados mediante la aplicación de SVD en redes neuronales sean publicados y difundidos en revistas científicas y conferencias especializadas, para compartir el conocimiento y promover la adopción de estas técnicas en la comunidad científica e industrial.

Desarrollar herramientas y software específicos que faciliten la implementación de SVD en el entrenamiento de redes neuronales, haciendo más accesible esta técnica para investigadores y profesionales sin necesidad de profundos conocimientos técnicos.

Fomentar la investigación en la combinación de SVD con otras técnicas de optimización y aprendizaje automático para explorar sinergias y desarrollar modelos aún más robustos y eficientes, ampliando las posibilidades de aplicación en diversos campos.

La investigación futura debería explorar la aplicación de SVD en otros contextos de análisis de materiales y su integración con otras técnicas de optimización. Esto permitirá maximizar la eficiencia y precisión de los modelos de aprendizaje automático, ampliando su aplicabilidad en diversas áreas industriales y científicas.

Referencias Bibliográficas

- Alayo, A., Soto, E., Hernández, H., y Milagros, M. (2021). Ciencias Informáticas, 14(5), 181-202.
<https://doi.org/http://publicaciones.uci.cu>
- Asociación Nacional de Ingenieros de Corrosión. (1 de Mayo de 2020). Estándares de corrosión.
<https://www.ampp.org/about/nace-history>
- Bassantes, E. (2018). Desarrollo de un programa interactivo para el cálculo y diseño de columnas aplicando el software Matlab. Universidad Técnica de Ambato.
<https://doi.org/https://repositorio.uta.edu.ec/bitstream/123456789/27815/1/Tesis%201246%20-%20Bassantes%20Clavijo%20Ebenezer%20Jamarhold.pdf>
- Becerra, R., Díaz, Y., y Challenger, I. (2014). El lenguaje de programación Python. Ciencias Holguín, 20(2), 1-13.
<https://doi.org/https://www.redalyc.org/articulo.oa?id=181531232001>
- Bouza, C., García, J., Moreno, A., y Rueda, M. (2017). Modelos Matemáticos para el Estudio del Medio Ambiente, Salud y Desarrollo Humano. Universidad de la Habana.
https://doi.org/https://www.researchgate.net/profile/Carlos-Bouza/publication/313797261_Modelos_Matematicos_para_el_Estudio_del_Medio_Ambiente_tomo_3_Salud_y_Development_Humano_Tomo_3/links/58a67c824585150402ee0806/Modelos-Matematicos-para-el-Estudio-del-Medio-Ambiente-to
- Cabanelas, J. (2019). Inteligencia artificial ¿Dr. Jekyll o Mr. Hyde? Mercados y Negocios, 1(40), 5-30.
<https://doi.org/https://www.redalyc.org/journal/5718/571860888002/571860888002.pdf>
- Carrasquero, E. (2022). DISEÑO DE MODELO MATEMÁTICO DE ANÁLISIS DE IMÁGENES PARA IDENTIFICACIÓN DE GRADO DE DESGASTE DE SUPERFICIES METÁLICAS POR EFECTOS AMBIENTALES. Universidad Estatal de Milagro.
https://doi.org/https://repositorio.unemi.edu.ec/bitstream/123456789/6075/3/GABRIEL_A%20VALENZUELA%20COBOS.pdf
- Cruz, J. (2021). Desenmascarando datos: Igualdad e Inteligencia Artificial. IUS, 15(48), 138-150.
<https://doi.org/https://www.scielo.org.mx/pdf/rius/v15n48/1870-2147-rius-15-48-137.pdf>

- Curcio, A., Blanco, N., y Reyes, R. (2015). El reciclaje como alternativa de manejos de desechos sólidos. *Scielo*, 39(86), 157-167. <https://doi.org/https://ve.scielo.org/pdf/ri/v39n86/art08.pdf>
- Díaz, C. (2014). Sistema óptimo para identificación de defectos de productos en una línea de producción. *Centro de Investigaciones en Óptica A. C.* <https://doi.org/https://cio.repositorioinstitucional.mx/jspui/bitstream/1002/833/1/15477.pdf>
- Jiménez, F. (2012). Redes neuronales y preprocesado de variables para modelos y sensores en bioingeniería. *Universitat Politècnica de Valencia.* <https://riunet.upv.es/bitstream/handle/10251/16702/tesisUPV3874.pdf>
- Mendoza, J., y Helmer, F. (2020). Modelos de redes neuronales artificiales, como sustento evaluativo al crecimiento pedagógico virtual en educación superior. *Educación superior*, 7(2), 26-36. http://www.scielo.org.bo/pdf/escepies/v7n2/v7n2_a06.pdf
- Mercado, D., Pedraza, L., y Martínez, E. (2015). Comparación de redes neuronales aplicadas a la predicción de series de tiempo. *Prospect*, 13(2), 88-95. <https://doi.org/http://www.scielo.org.co/pdf/prosp/v13n2/v13n2a11.pdf>
- Ocaña, Y., Valenzuela, L., y Garro, L. (2019). Inteligencia artificial y sus implicaciones en la educación superior. *Propósitos y Representaciones*, 7(2), 536-568. <https://doi.org/http://www.scielo.org.pe/pdf/pyr/v7n2/a21v7n2.pdf>
- Pedroza, R. (2014). Pedagogía para la práctica educativa del S. XXI. *Universidad Autónoma del Estado de México.* <https://doi.org/http://ri.uaemex.mx/bitstream/handle/20.500.11799/80067/Pedagogiia.pdf?sequence=1&isAllowed=y>
- Prieto, R., Herrera, A., Pérez, J., y Padrón, A. (2020). El modelo neuronal de McCulloch y Pitts interpretación comparativa del modelo. *Congreso Nacional de Instrumentación*, 1(1), 692-710. https://doi.org/ttps://www.researchgate.net/profile/Alejandro-Padron-Godinez/publication/333935129_COMPOR_TAMIENTO_BIESTABLE_EN_UNA_NEURONA_CON_UNA_AUTOSINAPSIS_Y_SU_RELACION_CON_LOS_FENOMENOS_DE_MEMORIA_A_CORTO_PLAZO/links/5d0d715a458515c11ced55e2/COMPORTAMIENTO-BIESTABL
- Quiñones, L., Ochoa, L., y Gamarra, O. (2020). Red neuronal artificial para estimular un índice de calidad de agua. *Revista Enfoque*, 11(2), 113-124. <https://doi.org/https://www.redalyc.org/journal/5722/572262509013/572262509013.pdf>
- Salazar, J. (2015). Introducción al fenómeno de corrosión: tipos, factores que influyen y control para la protección de materiales. *Scielo*, 28(3), 128-138. <https://doi.org/https://www.scielo.sa.cr/pdf/tem/v28n3/0379-3982-tem-28-03-00127.pdf>
- Stefannazi, R. (2022). La equivalencia formal en el lenguaje de las neuronas lógicas de McCulloch y Pitts. *Epistemología e historia de la ciencia*, 7(1), 23-43. <https://doi.org/https://revistas.unc.edu.ar/index.php/afjor/article/view/34428/40269>
- Taipe, C. (2019). Aplicación del software MATLAB en el aprendizaje de la cinemática lineal de una partícula en estudiantes universitarios de ingeniería. *Revista Innova Educación*, 1(3), 282-295. <https://doi.org/https://revistainnovaeducacion.com/index.php/rie/article/view/37/70>
- Tillería, L. (2022). Transhumanismo e inteligencia artificial: el problema de un límite ontológico. *Griot*, 22(1), 59-67. <https://doi.org/https://www.redalyc.org/journal/5766/576670028006/576670028006.pdf>
- Villate, J. (2019). Estudio de resistencia al desgaste y corrosión de recubrimientos de CrSiN sometidos a la acción de un flujo dinámico. *Universidad Pedagógica y Tecnológica de Colombia.* https://doi.org/https://repositorio.uptc.edu.co/bitstream/handle/001/3696/Resistencia_al_desgaste_y_corrosion.pdf?sequence=1&isAllowed=y
- Vizcarra, S. (2021). Determinación de parámetros óptimos de adsorción del plomo

(II) en aguas residuales industriales mediante un composito formado por piedra laja y cerámico. Universidad Nacional de San Agustín de Arequipa.
<https://doi.org/https://repositorio.unsa.edu.pe/server/api/core/bitstreams/b8b5014a-6451-4e02-87f0-979bbca2c743/content>

Yépez, J. (2021). Modelación matemática del riesgo por contaminación de suelos por metales pesados en Ecuador. Universidad Politécnica de Valencia.
<https://doi.org/https://riunet.upv.es/bitstrea>

[m/handle/10251/174774/Yepez%20-%20Modelacion%20matematica%20del%20riesgo%20por%20contaminacion%20de%20suelos%20por%20metales%20pesados%20en%20Ecuador.pdf;jsessionid=960AF5001531EAA592F0165E1FC31E3A?sequence=1](https://doi.org/https://riunet.upv.es/bitstream/handle/10251/174774/Yepez%20-%20Modelacion%20matematica%20del%20riesgo%20por%20contaminacion%20de%20suelos%20por%20metales%20pesados%20en%20Ecuador.pdf;jsessionid=960AF5001531EAA592F0165E1FC31E3A?sequence=1)



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © Alexandra Gabriela Valenzuela Cobos.

