

Maestría en Tecnologías de la Información



**TECNOLÓGICO
DE ESTUDIOS SUPERIORES
DE CUAUTITLÁN IZCALLI**

**T
E
S
C
I**

**”INCORPORACIÓN DE INTELIGENCIA
ARTIFICIAL PARA LA DETECCIÓN DE
CONSISTENCIA EN EL PROCESO DE
MOLIENDA BATCH EN UNA MÁQUINA DE
PAPEL”**

TESIS

**QUE PARA OBTENER EL GRADO DE: MAESTRO EN
MAESTRÍA EN TECNOLOGÍAS DE LA INFORMACIÓN**

PRESENTA:

ING. IVÁN PAREDES RAMÍREZ

DIRECTORA DE TESIS:

Dra. María de Lourdes Salinas Callejas

Septiembre de 2025



GOBIERNO DEL
ESTADO DE
MÉXICO



ESTADO DE
MÉXICO
¡El poder de servir!

EDUCACIÓN

SECRETARÍA DE EDUCACIÓN, CIENCIA, TECNOLOGÍA E INNOVACIÓN



TECNOLÓGICO
DE ESTUDIOS SUPERIORES
DE CUAUTITLÁN IZCALLI



"2025. Bicentenario de la vida municipal en el Estado de México".

Tecnológico de Estudios Superiores de Cuautitlán Izcalli

Dirección Académica

Subdirección de Apoyo y Desarrollo Académico

Departamento de Investigación y Desarrollo Tecnológico

Cuautitlán Izcalli, Estado de México a 03 de septiembre de 2025

TESCI/DIDT/147/IX/25

**DIRECCIÓN ACADÉMICA
DEPARTAMENTO DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO
COORDINACIÓN DE POSGRADO**

**INGENIERO
IVAN PAREDES RAMIREZ
PRESENTE**

Por este conducto me permito informarle que puede proceder a la digitalización del Trabajo de Tesis titulado:

**"INCORPORACIÓN DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE CONSISTENCIA EN EL
PROCESO DE MOLIENDA BATCH EN UNA MÁQUINA DE PAPEL"**

Ya que la comisión encargada de revisar el trabajo que se presenta para efectos de titulación, ha dado su autorización conforme a lo estipulado en el Lineamiento para la operación de los Estudios de Posgrado en el Sistema Nacional de Institutos Tecnológicos.

Sin nada más que agregar, quedo a sus órdenes para cualquier aclaración.

ATENTAMENTE

**DRA. ERIKA EMILIA CANTERA
DEPARTAMENTO DE INVESTIGACIÓN Y
DESARROLLO TECNOLÓGICO
COORDINACIÓN DE POSGRADO**



c.c.p. Archivo
Departamento de Titulación
Expediente del alumno



Av. Nopaltepec sin número, col. La Perla, C. P. 54740, Cuautitlán Izcalli, Estado de México.
Tels.: 55 5864 31 70 y 55 5864 31 71. Página web: tesci.edomex.gob.mx

DECLARATORIA DE AUTORÍA LITERARIA ORIGINAL

Yo, Iván Paredes Ramírez, alumno de la Maestría en Tecnologías de la Información del Tecnológico de Estudios Superiores de Cuautitlán Izcalli, declaro que la información que se presenta en este trabajo "Incorporación de Inteligencia Artificial para la Detección de Consistencia en el Proceso de Molienda Batch en una Máquina de Papel" ha sido investigada, analizada y redactada por mi total autoría, habiendo obtenido la información que se refiere en la bibliografía.

AGRADECIMIENTOS

Le agradezco a Dios la oportunidad de aprender más cada día y en esta ocasión me permitió encontrar un lugar en el laboratorio de química del TESCOI a cargo del Dr. Ricardo Arrieta, quien me permitió el uso de las instalaciones para la obtención de las muestras necesarias.

Le agradezco a mi esposa por su apoyo y su compañía.

Le agradezco a toda mi familia por el apoyo para la culminación de este proyecto.

Dedicatorias

A Nicole y Jared que me mueven para crecer cada día. Y a mi esposa Tania que se mantiene a mi lado apoyándome siempre.

Índice general

Resumen	11
Resumen	12
Introducción	13
Planteamiento del problema	15
Justificación	16
Hipótesis	16
Objetivos	17
Objetivo general	17
Objetivos específicos	17
Metodología	18
Plan de análisis de los resultados	19
1. Marco contextual	20
1.1. La Inteligencia Artificial en la industria del Estado de México	20
1.2. Industria de fabricación de pulpa, papel y cartón en el Estado de México	21
1.3. Procesos de la fabricación de papel	22
1.3.1. Pulpeo	22
1.3.2. Depuración y limpieza	23
1.3.3. Refinación	23
1.3.4. Formación	24
1.3.5. Prensado	24
1.3.6. Secado	24
1.3.7. Acabado	24
1.3.8. Molienda Batch	24
1.4. Segmentación de imágenes	25
1.5. Inteligencia artificial	25
1.5.1. Redes neuronales artificiales	26
1.5.2. Red Neuronal Convolutiva	26

2. Marco teórico	27
3. Marco metodológico	32
3.1. Captura de imágenes	33
3.2. Aumento de datos	34
4. Aplicación de la metodología y discusión de resultados	37
4.1. Arquitectura de la Red Neuronal Convolucional (RNC)	37
4.2. Implementación y entrenamiento de la RNC	38
5. Conclusiones y perspectivas para trabajos futuros	40
Bibliografía	41
ANEXOS	43
Anexo A. Planos del proyecto	43

Índice de figuras

1.1.	Gráfica del uso del internet en las unidades económicas en el Estado de México (INEGI, 2025).	21
1.2.	Proceso de la fabricación de papel (L. Mendoza, 2001).	23
1.3.	Hidrapulper tliipo batch.	25
2.1.	Diferencia entre clasificación, detección y segmentación, Fazakas et al., 2022	28
3.1.	Consistencia alta	34
3.2.	Consistencia normal	34
3.3.	Consistencia baja	36
3.4.	Muestras modificadas.	36
4.1.	Arquitectura típica de una red neuronal convolucional para clasificación de objetos (García, 2023).	38
4.2.	Resultados.	39

Índice de tablas

2.1. Esquema comparativo.	31
3.1. Diferentes pesos y consistencias de muestras tomadas.	33
3.2. Base de matrices para transformar geoméricamente las imágenes ori- ginales (Gonzalez y Woods, 2018).	35

Lista de Abreviaturas

IA Inteligencia Artificial. 6, 11, 14, 18–20, 23, 29, 38

IBk Instance Based k. 13

INEGI Instituto Nacional de Estadística y Geografía. 19

J48 Algoritmo de aprendizaje de máquina para datos categóricos y continuos. 13

RNC Red Neuronal Convolutacional. 7, 11, 12, 15, 18, 33, 35, 36, 38

Resumen

La fabricación de papel kraft es un comercio utilizado principalmente para el empaque secundario de bienes. Es necesario conocer que en la actualidad existen diferentes empresas que generan sus productos de papel kraft a partir de desechos, permitiendo así reciclar materiales que están dispuestos como basura. El proceso de la fabricación de papel kraft comienza con la molienda del material en molinos tipo batch, donde una de las variables críticas a monitorear es la consistencia, ya que grandes variaciones afectan el proceso más adelante de limpieza, bombeo, almacenamiento, refinación, formación, entre otros. Actualmente existen sensores de consistencia que permiten conocer el valor para dar control al proceso, pero estos llegan a tener variaciones significantes por basura, tapones, equipos, entre otros. Y su punto de lectura de datos es en tuberías durante el desplazamiento de un punto a otro, pero en la molienda el control se recarga fuertemente en el operador quien es el que regula la carga de material, suministro de agua y limpieza del molino. La investigación pretende mejorar y ayudar en la molienda para la toma de decisiones, por medio de inteligencia artificial y más específicamente, el uso de una red neuronal convolucional. Para esto será necesario crear imágenes con un sensor, el cual será colocado para evitar variaciones por la luz durante el trabajo o contaminación de este con material del molino. A estas imágenes se les realizará un filtrado para optimizarlas y servirán al entrenamiento de la red neuronal convolucional.

Palabras clave: Molienda, consistencia, sensor, inteligencia artificial, red neuronal convolucional, modelo de entrenamiento

Abstract

The manufacture of kraft paper is an industry primarily used for secondary packaging of goods. It is important to note that nowadays there are different companies that produce kraft paper products from waste, thus allowing the recycling of materials that would otherwise be discarded as garbage. The kraft paper manufacturing process begins with the grinding of the material in batch-type mills, where one of the critical variables to monitor is consistency, as large variations affect subsequent processes such as cleaning, pumping, storage, refining and formation. Currently, consistency sensors are available to measure values and provide process control, but these sensors can experience significant variations due to debris, clogs, equipment issues, and other factors. Their data reading point is in the pipes, measuring as the material moves from one point to another. In the milling stage, however, process control relies heavily on the operator, who regulates the material load, water supply and mill cleaning. This research aims to improve and assist the milling process in decision-making through artificial intelligence, specifically using a convolutional neural network. To achieve this, images will be captured using a sensor, which will be placed to avoid variations caused by light during operation or contamination from mill material. These images will be filtered for optimization and used to train the convolutional neural network.

Keywords: Milling, consistency, sensor, artificial intelligence, convolutional neural network, training model

Introducción

En este trabajo se tiene el tema principal del uso de la Inteligencia Artificial (IA) en el proceso de molienda batch de pacas de cartón para la posterior fabricación de papel Kraft. Es necesario el reducir variaciones en la molienda batch mediante la visualización del proceso para identificar de una mejor forma la consistencia que se tiene en el molino, para esto será necesario considerar una Red Neuronal Convolutiva (RNC) que se entrene con diferentes muestras del molino y sus respectivos valores de consistencia. La fabricación de papel depende bastante del proceso de molienda, ya que el obtener variaciones iniciales perjudica el control en los siguientes procesos, ya sea en equipos de limpieza, bombas, refinadores, formación y hasta en la extracción de humedad. Algunas máquinas de papel son solo con un secador Yakee (debido al bajo gramaje), otras difieren en mesas para la formación de fibras y en este caso se usan rodillos formadores por el rápido drenado desde la formación, pero en todas estas máquinas es importante mantener estable las variables críticas, siendo una de ellas la consistencia.

Los tiempos perdidos en el sector de fabricación de papel pueden ser por fallas de mantenimiento, operación, productos químicos, tipos de agua, pero los problemas por consistencia afectan a lo largo de todo el proceso de la fabricación, siendo primordial el contar con una consistencia adecuada para suministrar a la máquina, ya que estas perdidas crean una mal aprovechamiento de los recursos energéticos, fibra, monetarios, mano de obra, entre otros. Bajando así el rendimiento de la línea y por ende bajando las utilidades monetarias que se pueden llegar a obtener. La Inteligencia Artificial (IA) actualmente a comenzado su inmersión en la parte industrial con la combinación de algoritmos planteados con el propósito de crear máquinas que presenten las mismas capacidades que el ser humano. Una tecnología que todavía nos resulta lejana y misteriosa, pero que desde hace unos años está presente en nuestro día a día a todas horas. Siendo así que el objetivo principal es desarrollar una inteligencia artificial que razone el proceso de molienda batch a partir de imágenes del molino de merma.

La investigación no pretende generalizar en los diferentes tipos de máquinas y/o sistemas que existen en el mercado para la elaboración de papel, ni tampoco pretende estudiar todos los problemas que generan tiempo perdido o analizar todas las variables involucradas en el proceso de molienda batch, solo se enfocará en la variable primordial para el proceso de fabricación de papel, ya que como hace mención Becerril y Pallares, 2009 la consistencia influye en diferentes equipos para lograr mejores resultados.

Esta investigación enfocará su contribución a extender el uso de la inteligencia artificial, no solo a asistentes inteligentes, desarrollo de sistemas dirigidos a la militia o en recomendaciones personalizadas de consumo humano, sino también para el acompañamiento de la toma de decisiones en la fabricación de papel, realizando el primer paso en el entrenamiento de una Red Neuronal Convolucional (RNC) para reconocer el valor de la consistencia en el proceso de molienda.

Planteamiento del problema

La investigación se centrará en el departamento de procesos de la industria papelera enfocada en la molienda batch que se realiza en un trabajo continuo, donde el molinero se encarga de mantener el abastecimiento de las materias primas (agua, pacas) para mantener el flujo de pasta a los procesos siguientes; en la actualidad se tienen oportunidades de mejora, ya que el proceso difiere entre operadores marcando un trabajo desigual para un mismo propósito, donde se propone la ayuda de la inteligencia artificial es en tener un valor de consistencia como soporte adicional que apoye al operador en tener decisiones más estandarizadas.

En estudios anteriores donde se ha utilizado a la inteligencia artificial, Rocha et al., 2023 realizan clasificación de semillas a partir de datos de calidad entre las variables que encontraron fueron la germinación y pruebas en frío, esto para verificar la calidad fisiológica de los lotes. Concluyendo que pueden clasificarlos con gran precisión con el uso de los algoritmos IBk y J48, aplicando la técnica de aprendizaje automático.

Otro estudio del uso de la inteligencia artificial enfocada al reconocimiento de patrones en imágenes médicas, Santamaría, 2019 usa redes neuronales convolucionales para tal propósito, donde entrena a la red con un total de 7171 imágenes clasificadas en 5 tipos de tuberculosis, en su primer prueba logra obtener una exactitud de 78.7%, la cual busca incrementar al realizar una clasificación de 1310 imágenes por cada tipo de tuberculosis y al combinar los 5 tipos de tuberculosis, llegando a un porcentaje de exactitud del 88.1%. En la industria papelera me he percatado de que actualmente se tienen los siguientes problemas:

- La consistencia en el molino se mantiene a partir de la experiencia de los molineros y esta es ratificada con un sensor en tiempo real en la cabina de control, pero se corrobora el dato cada hora ya que los sensores dan falsos positivos por el aglomerado de basura que tienen las pacas de materia prima.
- Con respecto al uso de tecnologías se mantienen usando sensores de consistencia la salida del molino el cual entrega resultados de lo que va descargando el molino y no de la consistencia que se tiene actualmente.

El presente trabajo "INCORPORACIÓN DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE CONSISTENCIA EN EL PROCESO DE MOLIENDA BATCH EN UNA MÁQUINA DE PAPEL" tiene el propósito de disminuir la variabilidad en los equipos por la consistencia y además lograr un entrenamiento a los molineros de una forma más estandarizada.

Justificación

En la industria papelera se realiza un trabajo de manera continua, para mantenerlo así depende mucho de los cambios existentes en las variables críticas del proceso de molienda, limpieza de pasta, refinación, formación y retiro de humedad con parte mecánica y térmica. A lo largo de este proceso es importante el realizar el seguimiento de sus variables y prestar atención a las que comprometan el proceso, reduciendo así los datos de estudio. En este seguimiento se generan datos de información que pueden ser graficados o analizados, pero toma tiempo el realizarlo de manera individual y a cada uno de ellos, por lo que el tema central de esta investigación es analizar la consistencia en el procesos inicial de la fabricación de papel, la molienda batch. Generando un apoyo con la implementación de la Inteligencia Artificial (IA) para ayudar a facilitar la toma de decisiones en el proceso, disminuir el tiempo de respuesta de los involucrados y brindar el apoyo a una mejor decisión. Logrando así la eficiencia del proceso, no solo generando un sistema con una mayor disponibilidad y menor variabilidad, si no también facilitando la toma de decisiones y dejando tiempo a actividades de valor.

Se ha visto en la industria papelera una generación de desperdicio por mala calidad, pérdida de disponibilidad de la máquina por tiempos perdidos por un desaprovechamiento de los equipos y esto conlleva a una reducción de producción que al final deja un negocio poco rentable. En la actualidad se tiene un gran desarrollo de la Inteligencia Artificial (IA) con el uso de Redes Neuronales Convolucionales que dan paso al apoyo en la automatización de la industria y asisten en la toma de diferentes decisiones para reducir riesgos generados por la incertidumbre, esto se logra con el tiempo enfocado al entrenamiento.

Hipótesis

El valor de la consistencia de un molino tipo batch se puede obtener a partir del análisis de imágenes durante la molienda con una red neuronal convolucional.

Objetivos

Objetivo general

Entrenar una Red Neuronal Convolutiva (RNC) a partir de las imágenes obtenidas en un laboratorio (cada una con su respectivo valor de consistencia) con una resolución media, para imitar el proceso de molienda batch en la fabricación de papel, con la meta de disminuir la variabilidad de la consistencia que afecta los demás equipos hacia adelante en su operación y dar paso a una estandarización en el uso del molino al personal involucrado.

Objetivos específicos

- Buscar la posición ideal para colocar el sensor de imagen de media resolución en el molino, debido a la suciedad del proceso y cambio de luminosidad en las 24 hrs.
- Acoplamiento del sensor de imagen de media resolución a una tierra física para que no sea perturbado por el movimiento del proceso durante la obtención de fotografías digitales.
- Obtener fotografías digitales de media resolución con su respectiva consistencia en el molino de papel para el entrenamiento de la Red Neuronal Convolutiva (RNC).
- Desarrollar el algoritmo para la Red Neuronal Convolutiva (RNC) que logre aprender los cambios de consistencia durante el trabajo del molino.
- Entrenar la Red Neuronal Convolutiva (RNC) para que sea capaz de clasificar la pasta del molino en segmentos de 1 %, el intervalo de consistencia entre 2 % y 12 %
- Establecer si es posible reconocer a partir del entrenamiento de una Red Neuronal Convolutiva (RNC) las diferencias de consistencia observables durante el trabajo del proceso de molienda.

Metodología

La metodología se realizará de la siguiente manera:

- Como primer paso, se documentará a fondo en el procedimiento de papel, principalmente en la molienda tipo batch. Paralelamente a esto se hará el estado del arte de técnicas del aprendizaje profundo, en especial, el uso de redes neuronales para la identificación de patrones en imágenes, y sus diferentes configuraciones o arquitecturas.
- Se investigará el tipo de sensor necesario para un análisis que no requiera bastante recurso del computador y permita una fluidez en el análisis de los datos.
- Cuando se encuentre el sensor será necesario estar en piso para su colocación ya que este afectara la generación de imágenes debido a la iluminación o distancia. Se buscará una ubicación ideal que permita generar imágenes que permitan el estudio con el uso de inteligencia artificial.
- Creación de imágenes de prueba con ayuda de una manufacturera de papel, colocación del sensor de imágenes para una iluminación que beneficie a la imagen y la interpretación de cada una de ella con la realización de un ensayo para la obtención de la consistencia.
- Filtrado de imagenes para optimizar el procesamiento en la red neuronal y permitir obtener mejores resultados.
- Generación del algoritmo de una red neuronal convolucional para el procesamiento y tratamiento de las imágenes obtenidas.
- Analizar los resultados obtenidos y determinar el tipo de configuración necesitada para la red, además de las características del filtrado que permitieron subir el porcentaje de certidumbre en el entrenamiento de la red.

Plan de análisis de los resultados

Para el análisis de los datos obtenidos se obtendrá el desempeño de la red por medio del cálculo de la exactitud, en la ecuación 1 se muestra como se realizará.

$$e = \frac{\sum p}{n} \quad (1)$$

Donde,

e = exactitud del modelo

p = predicciones correctas

n = total de predicciones

Además, se dividirá en conjuntos de consistencias para realizar una validación cruzada, esto para obtener una evaluación más precisa del rendimiento del modelo, y realizar una comparación con respecto a la primera exactitud.

Capítulo 1

Marco contextual

1.1. La Inteligencia Artificial en la industria del Estado de México

La Inteligencia Artificial (IA) se ha convertido en una herramienta de la vida cotidiana debido a la implementación que se le puede dar en diferentes áreas de investigación, partiendo del desarrollo de la máquina de Turing que es un sistema matemático y con la posibilidad de resolver diversos cálculos posibles, donde genera y modifica combinaciones de símbolos binarios representados por 1 y 0, donde, se tiene el punto de partida para el desarrollo tecnológico que se ha realizado a lo largo de los últimos años, este avance permitió darle paso a los algoritmos computacionales, los cuales son reglas definidas para dar solución a muchos problemas que se nos han presentado y con una menor inversión de tiempo. Permitiendo dar paso al inicio del uso de las redes neuronales que son un modelo computacional que enlaza neuronas para incrementar o inhibir el peso de los valores de la salida, logrando así un aprendizaje automático, siendo la parte más importante de la inteligencia artificial que permite un aprendizaje en los códigos desarrollados del algoritmo sin tener que programarlo nuevamente, sino que es a partir del reconocimiento de patrones.

Los avances en aprendizaje profundo (deep learning) han permitido la creación de redes neuronales convolucionales (RNC) y otros modelos de inteligencia artificial que pueden detectar objetos, características y anomalías en imágenes con una precisión sin precedentes. Sin embargo, la implementación de estos sistemas enfrenta diversos desafíos, como la necesidad de grandes volúmenes de datos etiquetados, el alto costo computacional y la interpretabilidad de los resultados obtenidos.

Los diferentes procesos que se desarrollan en la industria manejan diferentes variables las cuales impactan de diferente manera al producto terminado, siendo que las variables críticas tienen mayor relevancia al estudiar el flujo de la materia prima en el proceso, esto es debido a que la falta del monitoreo de estas se traduce en menor eficiencia en la máquina, mayor desperdicio generado y menores ganancias obtenidas. Para obtener estas variables críticas hay que pensar en lo que busca el cliente de nuestro producto final e ir en todo el flujo de la materia prima dentro del proceso

analizando estas variables críticas de calidad, para permitir el estudio del grado de criticidad que tiene cada una de ellas.

A lo largo de la historia se ha buscado la forma de comunicarse y de perseverar la información para llevarla de un lugar a otro y de una época a otra. Plasmando esta información en paredes a partir de dibujos y evolucionando para generar un lenguaje de grafos que pudiera ser interpretado por comunidades. Fue así como en la antigua china se comenzó con el uso del papel y así llegó hasta Europa central en el siglo XI, llevado por las conquistas de los árabes y permitiendo plasmar diferentes ideas que con la imprenta le dan lugar al desarrollo de libros. Fue hasta 1801 (en apogeo de la revolución industrial) que Fourdrinier desarrolló la primera máquina de papel continua, dando así un comienzo al desarrollo tecnológico para aumentar capacidad de producción y con buena calidad en el producto terminado. En la actualidad se tienen varios sistemas para la fabricación de papel que dependen del tipo y el gramaje del papel.

Por primera vez en los censos económicos en el Estado de México que realiza el Instituto Nacional de Estadística y Geografía (INEGI) se ha incluido el tema relativo con el uso de la tecnología digital en las unidades económicas. Los datos revelaron que 16.2% de las unidades (121 503) empleó internet para sus actividades. Los usos más frecuentes fueron buscadores y repositorios, con 85.4 y 58.5 %, y solamente un 2 % para sistemas de Inteligencia Artificial, en la figura 1.1 se puede ver la distribución del uso del internet en las unidades económicas,



Figura 1.1: Gráfica del uso del internet en las unidades económicas en el Estado de México (INEGI, 2025).

1.2. Industria de fabricación de pulpa, papel y cartón en el Estado de México

Según datos del Censo Económico realizado por la Secretaría de Economía, 2019; en el país de México se cuenta con una producción bruta total de \$83 559 millones de

pesos mexicanos, de los cuales \$16 788 millones de pesos mexicanos son por industrias papeleras del Estado de México y en segundo puesto se encuentra el estado de Nuevo León con \$15 543 millones de pesos mexicanos.

Se totalizaron un total de 316 unidades económicas en fabricación de pulpa, papel y cartón, destacando 151 en el estado de Puebla, 43 en el estado de México y 20 en el estado de Nuevo León. Todas y cada una de ellas en su proceso llevan molienda en la cual se está realizando esta investigación para apoyar al personal a mitigar variaciones de consistencia.

Además de los datos económicos, resulta relevante considerar el papel que puede desempeñar la Inteligencia Artificial (IA) en el acompañamiento de los procesos industriales, particularmente mediante el uso de procesamiento de imágenes. Esta tecnología permite analizar en tiempo real las condiciones del material durante la molienda, identificar variaciones en la consistencia y generar alertas automáticas que faciliten la toma de decisiones operativas. La integración de soluciones basadas en IA no solo contribuye a una mayor precisión en el monitoreo, sino que también representa una herramienta clave para optimizar la eficiencia del proceso y reducir errores humanos en entornos industriales complejos.

1.3. Procesos de la fabricación de papel

El proceso a grandes rasgos de la fabricación de papel se puede ver en la figura 1.2. Estos son los siguientes:

- Pulpeo
- Depuración y limpieza
- Refinación
- Formación
- Prensado
- Secado
- Acabado

Llega a cambiar dependiendo de cuantos equipos de limpieza se consideren o tanques de almacenamiento de pasta haya distribuidos a lo largo del proceso, además de la formación del papel que puede ser por formadores o en esta figura se ve el ejemplo de formación por tela.

1.3.1. Pulpeo

Es la elaboración de una mezcla que en grandes rasgo se trata de agua con pacas de papel reciclado del desperdicio, con la finalidad de hacer pasta o pulpa que haga




Figura 1.2: Proceso de la fabricación de papel (L. Mendoza, 2001).

sencillo su transporte en los diferentes procesos de fabricación y se pueda trabajar con ella. Dentro de este se utiliza un pulper que des-fibrila por atrición que es la acción hidromecánica que ocurre en cercanías del impulsor.

1.3.2. Depuración y limpieza

Terminado el pulpeo, es necesario realizar una depuración y limpieza de la suspensión obtenida con el fin de retener partículas indeseables, que pudieran dañar la máquina de papel (o afectar la calidad del papel que requiera cumplir con estándares de limpieza muy elevados). Entre los dispositivos de limpieza mas usuales se encuentran los hidro-ciclones, éstos son recipientes de fondo cónico en cuya parte superior se suministra tangencial mente y bajo presión la suspensión fibrosa diluida aproximadamente a 2.5 % de consistencia. La fuerza centrífuga proporcionada proyecta a las partículas más pesadas que la fibra contra las paredes del recipiente provocando que descendan hasta el fondo de este, donde son desechadas (L. Mendoza, 2001).

1.3.3. Refinación

En la refinación se realiza la aplicación de fuerza mecánica sobre la fibra. El propósito de esta acción es modificar a la fibra para que cumpla con los parámetros de calidad establecidos. Esto permite fibrilar externa e internamente a la fibra y además el de cortar en partes más pequeñas que pueden llegar ser finos. Al generar la fibrilación se incrementa la capacidad de adhesión ya que aumentan la superficie de contacto entre ellas y generando mayores puntos de unión. Por lo tanto los papeles quedan más densos, duros y resistentes que con una falta o poca refinación. Con el envío de la pasta refinada al tanque de máquina, se dan por concluidas las operaciones asignadas al área de preparación de pastas.

1.3.4. Formación

Con la pasta en buen estado se pasa a un tanque, el cual descargará directamente a los formadores o caja de formación; siendo un recipiente donde se inundan los formadores y entregan la pasta a un fieltro (para fabricación por formadores) o descarga la pasta en forma laminar sobre el ancho de la tela en la mesa de formación (para fabricación FOURDRINER), el recorrido del fieltro o tela promueven el retiro de agua de manera natural por su drenabilidad, además su recorrido pasa a través de cajas de succión para promover la eliminación de agua que trae la recién hoja formada.

1.3.5. Prensado

El siguiente paso de la formación de la hoja es entregarla al prensado, donde por medio de cierto número de NIP's (puntos de prensado) se pretende retirar mecánicamente la mayor cantidad de agua posible con cierta presión aplicada a las prensas, ayudando a darle las características que se requieren como producto final. Además, los fieltros ocupados en esta etapa tienen una regadera de limpieza y una regadera de lubricación que ayudan a mantener sus propiedades durante su tiempo de vida, este excedente de agua más el agua retirada del papel se eliminan con una caja de vacío.

1.3.6. Secado

A la salida de las prensas se entrega la hoja a la etapa de secado donde es conducida a pasar por cierto número de secadores metálicos, calentados con vapor internamente, que se encargan de retirar el excedente de agua en la hoja por medio de intercambio de temperaturas.

1.3.7. Acabado

Antes de terminar el proceso el papel pasará por otra sección de NIP's en rodillos de acero, denominadas calandrias, en este proceso el producto adquirirá una característica más, la que se le denomina con satinado.

El satinado depende de la clase de papel que se fabrique y le brindará tersura y lustre, inmediatamente después el papel será enrollado donde se entregará al área de embobinado.

1.3.8. Molienda Batch

Una vez que se ha descrito el proceso general de la fabricación de papel, nos centraremos en la molienda donde realizaremos la investigación. En la molienda existen dos maneras para realizarlo, la de tipo batch y continua. La tipo batch mantiene una alimentación intermitente lo cual genera variaciones en el proceso que pueden ser amortiguadas más adelante, pero estas no pueden ser muy bruscas, ya que afecta a equipos inmediatos de limpieza.




Figura 1.3: Hidrapulper tipo batch.

1.4. Segmentación de imágenes

La segmentación es una de las etapas cruciales de cualquier sistema de análisis de imágenes, tanto por las dificultades que conlleva como por la importancia de sus resultados. Básicamente, la segmentación puede considerarse como la partición de una imagen en un conjunto de regiones, homogéneas respecto a algún criterio y cuya unión cubra la imagen completa. En otras palabras es separar los objetos de interés de la imagen de los que son considerados como fondo (E. Mendoza, 2014). El método de la segmentación de imágenes es asignar una etiqueta a cada píxel en la imagen, los que tienen la misma etiqueta comparten ciertas características visuales.

1.5. Inteligencia artificial

En forma básica, la Inteligencia Artificial (IA) es un campo interdisciplinario que fusiona la informática con conjuntos extensos de datos para resolver una variedad de problemas. Dentro de este ámbito, se incluyen el aprendizaje automático y el aprendizaje profundo, áreas estrechamente relacionadas que se mencionan frecuentemente junto con la inteligencia artificial. Dichas disciplinas se caracterizan por algoritmos avanzados diseñados para desarrollar sistemas expertos capaces de realizar predicciones precisas y clasificaciones detalladas utilizando información de entrada específica.

Es una rama de la ciencia de la computación que se enfoca en proporcionar a un software, con la capacidad de mostrar un comportamiento “inteligente” al momento de determinar una decisión. Se necesitan diferentes maneras para poder “representar el conocimiento” de interés a un software de tal manera de que este la pueda “Razonar”. El razonamiento de la inteligencia artificial permite dar como resultados nueva información relevante y la correcta implementación de la representación del conocimiento junto con un buen razonamiento en el campo de la inteligencia artificial permite a un software resolver o analizar problemas que hubiesen requerido la intervención de un experto humano.

1.5.1. Redes neuronales artificiales

En las ciencias de la computación se sabe que el primer trabajo donde se modela una red neuronal artificial es en el artículo clásico de John McCarthy titulado como “Programs with Common Sense” de 1959 declara que “Para que un programa sea capaz de aprender algo, primero se le tiene que poder decir”. Esto quiere decir que se debe proporcionar las instrucciones de forma completamente clara a través de la escritura de un código sin ambigüedades para que el programa tenga el comportamiento deseado. Esto crea la “lógica” de un programa, y siempre tiene como objetivo guiar al programa hacia un razonamiento adecuado sobre un área específica. Escribir un código para crear un nuevo programa, es un proceso complejo. Se necesita conocimiento de un avanzado lenguaje de programación que pueda ser leído, comprendido procesado y ejecutado por la línea de comandos de un sistema operativo. Estos lenguajes, se rigen bajo su propia sintaxis para poder ser interpretados correctamente por el compilador del programa.

1.5.2. Red Neuronal Convolutacional

Existen varias arquitecturas de redes computacionales, y entre ellas destacan las Redes Neuronales Convolucionales (CNN por sus siglas en inglés), ya que han mostrado gran desempeño en la tarea de clasificación de imágenes. Esta configuración de red multicapa y multilíneal extrae en una primera fase las características de una imagen, para luego clasificarla a través del recorrido por una red entrenada por retropropagación. Este método de aprendizaje supervisado permite a través del análisis de un amplio banco de datos, el refinamiento de un modelo entrenado (algoritmo), el cual mejora conforme más datos procesa, lo que le permite obtener con el tiempo resultados cada vez más optimizados para cumplir con una tarea deseada. La inspiración de la creación y funcionamiento de las redes neuronales artificiales fue a partir de un proceso similar a la fisiología neuronal cerebral ya que utiliza una serie de nodos interconectados entre sí que, al cumplir ciertos criterios, se estimulan de manera no lineal lo que finalmente llega a la determinación de resultados, esta unidad básica es llamada perceptrón.

Capítulo 2

Marco teórico

En los últimos años, el uso de técnicas de inteligencia artificial, especialmente el aprendizaje profundo, ha transformado el análisis de imágenes en diversos sectores industriales. Entre estas técnicas, las redes neuronales convolucionales (CNN) han destacado por su capacidad para extraer y aprender automáticamente características visuales complejas a partir de grandes volúmenes de datos, lo que las hace especialmente útiles en tareas de clasificación, segmentación y detección de patrones en imágenes.

La clasificación de imágenes es asignar categorías específicas a diferentes clases. Esto genera un problema ya que con datos de entrenamiento el algoritmo debe de ser capaz de predecir si pertenece a cierta clasificación o no. A partir de esto las redes neuronales convolucionales han demostrado ser excelentes en tareas de clasificación, ya que pueden obtener lo más relevante de las imágenes muestreadas.

Cuando hablamos de detección de objetos lo principal que debemos de determinar es si un objeto de una categoría están presentes o no en ciertas imágenes, según Fazakas et al., 2022 existen dos tipos de métodos para la detección de objetos:

- Enfoque basado en propuestas: el algoritmo selecciona regiones dentro de la imagen y luego las clasifica en categorías (algunas redes utilizadas son R-CNN, Fast R-CNN y Mask R-CNN).
- Enfoque basado en regresión: con este se utiliza un marco unificado que realiza de forma directa la clasificación y localización en la imagen (algunas redes utilizadas son MultiBox, YOLO (You Only Look Once) y RetinaNet).

Finalmente la segmentación es la partición de los píxeles de una imagen en grupos llamados segmentos de imagen. Lo que equivale a delimitar los contornos del área o volumen de interés.

En la figura 2.1 se puede apreciar mejor la diferencias entre la clasificación, la detección y la segmentación en una imagen.




Figura 2.1: Diferencia entre clasificación, detección y segmentación, Fazakas et al., 2022

Aunque el uso de CNN se ha generalizado en campos como la medicina, donde se emplean para el diagnóstico a partir de imágenes radiológicas y microscópicas (Machado y Aparicio, 2021), también han comenzado a implementarse en procesos industriales. Por ejemplo, según Morales, 2024 las redes neuronales convolucionales pueden automatizar la identificación de componentes electrónicos, optimizando procesos de ensamblaje y control de calidad en la industria electrónica.

Estas aplicaciones son directamente transferibles a entornos industriales como el de los molinos de papel, donde es posible entrenar modelos CNN para analizar imágenes captadas durante el proceso de molienda o reciclaje de pulpa. En este contexto, las CNN pueden correlacionar características visuales —como textura, color, forma y densidad aparente— con parámetros físico-químicos del material, incluyendo la consistencia de la suspensión de fibras. De este modo, la IA no solo puede detectar desviaciones en tiempo real, sino también anticipar ajustes en el proceso para mantener una calidad constante.

Además, las investigaciones realizadas en redes neuronales artificiales han dado avances significativos para el aprendizaje de máquina (machine learning) en comparación con la programación tradicional, donde los algoritmos; las entradas y salidas; y la codificación dependen del programador que lo ha realizado. En cambio, las redes neuronales artificiales dependen de un algoritmo capaz de aprender a partir de datos de entrenamiento y así se adaptan a nuevas situaciones, permitiendo que tome decisiones según datos y patrones. Las redes neuronales artificiales se han usado ampliamente en áreas de reconocimiento de patrones en imágenes, voz y vídeo. Para continuar abordaremos tres tipos de redes neuronales con las que se han realizado trabajos enfocados a imágenes:

Red neuronal recurrente (RNN).

El uso de redes neuronales recurrentes se ha desarrollado en problemas donde los datos pueden ser trabajados como vectores. Algunos ejemplos donde se puede observar su uso son en la búsqueda por voz, traducción de idioma, patrones en gráficas

financiera debido a que es sencillo colocar tiempos para que pueda generar memoria la red y además trabajar en bi-dirección lo que se logra al considerar datos futuros y datos pasados para el desempeño de la red (esto genera dos tipos de redes neuronales recurrentes las cuales son *Long Short-Term Memory* LSTM y *Bidirectional Long Short-Term Memory Network* Bi LSTM).

Hernández, 2021; ha realizado una investigación en la predicción de sismos a partir del análisis de sismogramas con el uso de redes neuronales recurrentes y con una recolección de sismogramas de diferentes eventos sismológicos. El uso de este tipo de red neuronal se debe a que este algoritmo tiene la capacidad de “recordar” características o rasgos importantes en las secuencias de datos.

Encontró que el uso de una red neuronal simple (Vanilla), es capaz de capturar el comportamiento que rige la propagación de las ondas sísmicas a través de medios elásticos, de otra forma, las redes neuronales recurrentes no habrían sido capaces de realizar predicciones tan cercanas a los valores reales. En cuanto al entrenamiento solo se utilizó una gráfica, lo cual a futuro puede llegar a complementarse con la adición de más sismogramas y componentes espaciales.

En conclusión, el uso de redes neuronales recurrentes puede ser beneficioso para aplicaciones unidimensionales porque resulta en menos uso de recursos en el procesamiento de vectores de datos y no en matrices de datos.

Red neuronal convolucional (CNN).

En diferentes trabajos se usan las redes neuronales convolucionales para identificar patrones en imágenes, ya que se aprovechan los principios del álgebra lineal, que permiten trabajar datos en forma de matrices por la facilidad de multiplicarlos. El mayor inconveniente con el uso de estas redes es la demanda de procesamiento gráfico desde el entrenamiento de la red.

García, 2023; utiliza una red neuronal convolucional VGG16, para detectar desgaste en piezas metálicas utilizadas en la ortodoncia, logrando una exactitud de 83.26 % en clasificar las piezas como nuevas, primer uso y tercer uso. En su investigación se logra ver que investigaciones similares se han enfocado a instrumentos de corte para la manufactura como lo son fresa de bola, brocas o herramientas de inserción y perforación. Concluye en tener problemas con la detección de cambios mínimos en su estudio lo que se representó en el bajo porcentaje obtenido, lo cual recomienda para futuras investigaciones la creación de una base de datos más robusta para el entrenamiento de la red en la tarea compleja.

Sensor óptico Valmet.

Actualmente, la industria papelera cuenta con soluciones avanzadas para la medición de la consistencia en procesos de pulpa y papel. Un ejemplo destacado es el sensor óptico Valmet OC2R (Valmet, 2021), diseñado para medir la consistencia total y de cenizas en aplicaciones de preparación de pulpa reciclada. Este sensor se instala

directamente en la tubería del proceso, utilizando múltiples canales de fibra óptica y una única fuente de luz para proporcionar mediciones precisas y confiables. Su diseño permite una instalación rápida, con una sonda retráctil y auto limpiable que facilita el mantenimiento sin necesidad de detener el proceso. Además, el Valmet OC2R, según Valmet, 2021 es resistente a altas temperaturas, presiones y vibraciones, lo que lo hace adecuado para entornos industriales exigentes. Sin embargo, su integración requiere modificaciones en la infraestructura existente y está orientada a mediciones en línea dentro del proceso. Por otro lado, la propuesta de esta investigación consiste en desarrollar un sistema de procesamiento de imágenes asistido por inteligencia artificial que funcione de manera externa al proceso principal, operando como un operador visual automatizado. Este sistema analizará la pasta en el momento en el que se encuentra en su transformación a pulpa antes de incorporarse al sistema. Esta aproximación no solo reduce la complejidad de instalación, sino que también amplía los valores de la consistencia a partir de la forma de la pasta en el molino, lo que permite la disminución de variaciones que se integren al proceso más adelante. En la tabla 2.1 se muestra la comparación del sensor de valmet contra la propuesta de esta investigación.

Característica	Valmet OC2R	Sistema propuesto
Ubicación de instalación	Directamente en la tubería del proceso	Estación externa al proceso
Método de medición	Óptico (fibra óptica y luz)	Visual (cámaras y algoritmos de IA)
Requiere modificaciones	Sí (integración en la infraestructura existente)	No (instalación independiente)
Mantenimiento	Bajo (sonda retráctil y auto limpieza)	Bajo (sin contacto directo con el proceso)
Tipo de datos	Consistencia total y de cenizas	Clasificación de merma y residuos
Flexibilidad	Limitada a las condiciones del proceso	Alta (adaptable a diferentes tipos de merma y condiciones)
Costo de implementación	Alto (modificaciones en infraestructura)	Moderado (equipos de visión y computación)
Aplicaciones	Medición en línea de consistencia	Inspección de la consistencia antes de su incorporación al proceso

Tabla 2.1: Esquema comparativo.

Aunque la mayoría de las aplicaciones de IA en relación al procesamiento de imágenes se han centrado en áreas como la medicina y la ingeniería civil, su integración en la medición de consistencia en molinos de papel representa una área emergente. La combinación de sensores ópticos con algoritmos de IA podría mejorar la precisión y adaptabilidad de las mediciones de consistencia, permitiendo un control más eficiente del proceso de producción y una mejor calidad del producto final.

Capítulo 3

Marco metodológico

En el laboratorio de química del Tecnológico de Estudios Superiores de Cuautitlán Izcalli se realizaron diferentes mezclas entre papel y agua para obtener muestras similares a las que se obtienen en un molino tipo batch en la industria, de las diferentes muestras se cálculo la consistencia con la ecuación 3.1 de la norma T 240 om-93 TAPPI, 1993:

$$c = \frac{w}{g} \times 100 \quad (3.1)$$

Donde,
c = consistencia de la muestra
w = peso de muestra sin contemplar pesos adicionales por usar papel filtro
g = peso neto de la muestra original (agua y pasta)

En la norma se menciona que se debe de contemplar un horno a una temperatura de $105 \pm 3^\circ\text{C}$. Y secar por el tiempo necesario hasta que el peso seco sea constante.

Bajo estas premisas, el procedimiento para obtener la consistencia de las muestras creadas en el laboratorio fue pesar un vaso de precipitado vacío; verter la muestra en el vaso de precipitado y pesar la muestra; drenar la mayor cantidad de agua posible y colocar la hoja en el horno por 2 horas (tiempo donde se mantiene constante el peso seco); tomar el peso de la muestra seca y finalmente se obtiene la consistencia usando la ecuación 3.1, donde w = es el peso que obtuvimos de la muestra seca y g = es el peso del vaso de precipitado menos el peso del vaso de precipitado vacío.

A continuación se muestra un aglomerado de muestras tomadas y medidas en la tabla 3.1:

Muestra	Peso neto de muestra con vaso (gr)	Peso vaso precipitado (gr)	Peso neto de muestra (gr)	Peso seco (gr)	Consistencia (%)
1	414.94	287.4	127.54	3.24	2.54
2	437.52	287.4	150.12	3.60	2.40
3	392.66	287.4	105.26	2.67	2.54
4	388.10	287.4	100.70	2.59	2.57
5	389.92	287.4	102.52	2.72	2.66
6	384.24	287.4	96.84	1.20	1.24
7	361.20	287.4	73.80	0.91	1.23
8	281.04	209.2	71.84	0.81	1.14
9	295.32	209.2	86.12	1.29	1.51
10	302.46	209.2	93.26	0.82	0.88
11	279.06	209.2	69.86	0.68	0.98
12	282.16	209.2	72.96	0.85	1.18
13	375.84	209.2	166.64	1.74	1.05

Tabla 3.1: Diferentes pesos y consistencias de muestras tomadas.

3.1. Captura de imágenes

Para la captura de imágenes se considero realizarlas como primer prueba con el celular para llevarlas al modelo realizado en Python en la computadora. Actualmente los celulares cuentan con cámaras potentes por lo que la alta resolución deja sobrada el requerimiento de la imagen, sin embargo es necesario disminuir la resolución en primera parte no es necesario tanto detalle y en segunda parte disminuir el consumo computacional.

Una vez que se tienen las muestras de pulpa, a cada una de ellas se le tomaron varias fotografías desde la parte superior en diferentes ángulos y distancias para aumentar la diferencia entre cada una de las imágenes de muestreo y así el modelo sea más eficiente para identificar la consistencia sin considerar las irregularidades en la captura de la fotografía.

En la figura 3.1 se puede ver una consistencia alta, lo que hace la diferencia es que en la suspensión se tiene mayor papel y genera esa grumosidad que ayuda a la clasificación de la imagen. El valor de la consistencia alta debe de encontrarse entre 2.5 % o más.

En la figura 3.2 se encuentra el ejemplo de una pasta con consistencia normal, el valor de la consistencia normal se encuentra en 2.5 %.

Y finalmente en la figura 3.3 se puede notar el valor de la consistencia baja que debe de ser menor a 2.5 %. En este tipo de imágenes como la mezcla tiene poca pasta y mayor agua, en las imágenes se aprecia un color sin muchas texturas.




Figura 3.1: Consistencia alta



Figura 3.2: Consistencia normal

3.2. Aumento de datos

Para generar un aumento de datos tomando la muestra inicial, podemos usar las herramientas que pertenecen al aprendizaje automático; con esta herramienta se realizan transformaciones de manera automática basándose de los datos iniciales. Este procedimiento lo realiza mediante transformaciones geométricas para la modificación de los píxeles. Dichas transformaciones pueden ser de rotación, reflexión, escalamiento, inclinación y traslación. Estas transformaciones permiten generar variaciones en los datos que enriquecen el modelo, mejorando su capacidad de generalización.

Para lograr la transformación geométrica de la imagen, esta se debe de multiplicar por una matriz de transformación $\mathbf{T}$ y el resultado final dependerá de como este compuesta esta matriz. En la tabla 3.2 se listan las matrices para realizar las diferentes transformaciones geométricas.

Nombre de la transformación	Matriz afín	Ecuaciones de coordenadas	Ejemplo
-----------------------------	-------------	---------------------------	---------







Idéntica	$\begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$	$\begin{aligned} x' &= x \\ y' &= y \end{aligned}$	
Escalado o reflexión (para reflexión hay que colocar en uno de los valores -1 y en el otro 0)	$\begin{bmatrix} c_x & 0 & 0 \\ 0 & c_y & 0 \\ 0 & 0 & 1 \end{bmatrix}$	$\begin{aligned} x' &= c_x x \\ y' &= c_y y \end{aligned}$	
Rotación (en origen)	$\begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix}$	$\begin{aligned} x' &= x\cos\theta - y\sin\theta \\ y' &= x\sin\theta + y\cos\theta \end{aligned}$	
Traslación	$\begin{bmatrix} 1 & 0 & t_x \\ 0 & 1 & t_y \\ 0 & 0 & 1 \end{bmatrix}$	$\begin{aligned} x' &= x + t_x \\ y' &= y + t_y \end{aligned}$	
Inclinación (verti- cal)	$\begin{bmatrix} 1 & s_v & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$	$\begin{aligned} x' &= x + s_v \\ y' &= y \end{aligned}$	
Inclinación (horizon- tal)	$\begin{bmatrix} 1 & 0 & 0 \\ s_h & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$	$\begin{aligned} x' &= x \\ y' &= xs_h + y \end{aligned}$	

Tabla 3.2: Base de matrices para transformar geométicamente las imágenes originales (Gonzalez y Woods, 2018).

Para obtener las muestras mostradas en la figura 3.4, se aplicaron transformaciones geométricas a la imagen original utilizando las matrices de transformación que se comentan en la tabla 3.2. La imagen muestra fue multiplicada por esta matriz $\mathbf{T}$ obteniendo un aumento de muestras modificadas para el trabajo de la RNC.



Figura 3.3: Consistencia baja




Figura 3.4: Muestras modificadas.

Capítulo 4

Aplicación de la metodología y discusión de resultados

El desarrollo de la Red Neuronal Convolutiva (RNC) para la clasificación de consistencias se realizó utilizando una resolución de 300x300 píxeles. Esta decisión fue tomada con el objetivo de optimizar los recursos computacionales, ya que se anticipa que el modelo se implementará en un entorno de trabajo real, como en una planta papelera, donde es fundamental que el modelo realice las predicciones en intervalos de tiempo lo más cortos posibles. Al trabajar con imágenes de menor resolución, se reduce el costo computacional asociado con el procesamiento y la memoria, lo que permite que el modelo opere de manera eficiente en dispositivos con capacidades limitadas.

Cada entrada de la red neuronal corresponde a una imagen de 300x300 píxeles, y se asegura que todas las imágenes de entrada sean de este tamaño para garantizar la consistencia del proceso de entrenamiento. Este ajuste se hizo con el fin de que las imágenes tengan las mismas dimensiones y puedan ser procesadas de manera uniforme por la red neuronal, evitando cualquier distorsión que podría surgir al tener entradas de tamaños variables.

4.1. Arquitectura de la Red Neuronal Convolutiva (RNC)

La arquitectura de la Red Neuronal Convolutiva (RNC) desarrollada para esta tarea consta de tres capas ocultas, las cuales son convolucionales y extraen características clave de las imágenes de entrada, como bordes, texturas y patrones geométricos, que son cruciales para la clasificación de la consistencia. Después de estas capas, la red neuronal pasa a través de una capa densa, que se encarga de aglomerar los resultados obtenidos en las capas anteriores para generar una respuesta final. Esta capa densa facilita la toma de decisiones al proporcionar una salida clasificada.

En la figura 4.1, se muestra la arquitectura básica de una red neuronal convolutiva que se emplea en tareas de clasificación de objetos. Y ha sido adaptada para

lograr un buen balance entre precisión y eficiencia computacional en la clasificación de la consistencia.




Figura 4.1: Arquitectura típica de una red neuronal convolucional para clasificación de objetos (García, 2023).

4.2. Implementación y entrenamiento de la RNC

Para implementar y entrenar la red neuronal, se utilizó la API Keras en Python, una herramienta ampliamente utilizada en el desarrollo de redes neuronales debido a su facilidad de uso y flexibilidad. Keras permite construir, entrenar y evaluar modelos de redes neuronales de manera sencilla, lo que hizo de esta herramienta una opción ideal para este proyecto. Además, Keras está integrado con TensorFlow, lo que proporciona acceso a poderosos recursos computacionales que mejoran el rendimiento durante el entrenamiento y la ejecución del modelo.

El proceso de entrenamiento involucró la alimentación de imágenes de consistencias variadas a la red neuronal para que esta pudiera aprender a identificar las características que diferencian cada tipo de consistencia. Aunque el modelo logró identificar diferentes imágenes correctamente, los resultados, como se muestra en la Figura 4.2, aún presentan un margen de error considerable. Este margen de error indica que, si bien la red ha aprendido algunas características de las imágenes, aún hay espacio para mejorar en cuanto a precisión y eficiencia, especialmente en condiciones de variabilidad en las imágenes o en datos de prueba no vistos anteriormente.




Figura 4.2: Resultados.

Capítulo 5

Conclusiones y perspectivas para trabajos futuros

El uso de la Inteligencia Artificial en el proceso de molienda de tipo bacheo en la industria papelera le ha dado un apoyo a los operadores en sus tareas rutinarias permitiendo que trabajen de una manera similar y mantengan los estándares durante el proceso continuo, sin variaciones de consistencia, esto permite que la calidad del papel sea repetible y continua durante el proceso de fabricación. En este caso la clasificación de imágenes con el uso de Red Neuronal Convolutiva (RNC) fue adecuada al tener 3 clasificaciones finales, aunque existen muchos sensores de consistencia como lo es el de valmet OC2R (sensor óptico comparado en el proyecto) que pueden estar incorporados al sistema, todos sirven para dar una retroalimentación al lazo de control, lo que pide ajustes por medio del control de apertura del agua o de la velocidad de la alimentación por medio de la banda transportadora, lo que eleva costos al aumentar dispositivos robustos para el control. Con el uso de las Red Neuronal Convolutiva permite tener un operador más en piso que a partir del entrenamiento va mejorando en su clasificación final.

Para el futuro es recomendable mantener la alimentación de fotografías de la pasta para que el sistema pueda dar mejores resultados. De igual manera sería interesante comparar el sistema de la clasificación de consistencia con un sistema a partir de segmentación para que pueda dar un valor de consistencia real y ver si es capaz de dar un valor más preciso y cercano al real. Además que el uso de la Inteligencia Artificial en el Estado de México es un campo que se puede explotar por mucho tiempo ya que en las industrias instaladas actualmente solo el 2% de ellas usa la inteligencia artificial en sus procesos, lo que lo hace un campo ventajoso para la creación de nuevos negocios con el enfoque en la IA.

Espero que esta investigación sea pionera para muchos proyectos más, con el enfoque de la incorporación de la Inteligencia Artificial en los diferentes procesos que se realizan a diario en las industrias del Estado de México.

Bibliografía


- Becerril, D., & Pallares, J. (2009). Procesos de obtención de pulpa en México para la fabricación de papel y cartón a partir de fibra reciclada.
- de Economía, S. (2019). Acerca de Fabricación de Pulpa, Papel y Cartón. Consultado el 1 de julio de 2025, desde <https://www.economia.gob.mx/datamexico/es/profile/industry/pulp-paper-and-paperboard-mills?optionsSelector1=Economic%20Unit>
- Fazakas, S., Budai, B., Stollmayer, R., Kaposi, P., & Bérczi, V. (2022). Artificial intelligence and neural networks in radiology – Basics that all radiology residents should know. *AKJournals*, 14(2), 73-81.
- García, A. (2023). *Red Neuronal Convolucional para Clasificar Cambios Físicos en el Instrumento Wave One Gold Primary* [Tesis de maestría, Benemérita Universidad Autónoma de Puebla].
- Gonzalez, R., & Woods, R. (2018). *Digital Image Processing*. Global Edition.
- Hernández, L. (2021). *Análisis de Sismogramas mediante Redes Neuronales Recurrentes* [Tesis de maestría, Universidad Nacional Autónoma de México].
- INEGI. (2025). Censo economico (CE) Estado de México. Consultado el 6 de julio de 2025, desde https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2025/ce/CE_2024_ROMex.pdf
- Machado, A., & Aparicio, L. (2021). Técnicas de inteligencia artificial aplicadas al análisis de imágenes diagnóstico. *Eco Matemático*, 12(2), 100-111.
- Mendoza, E. (2014). *Segmentación del mesencéfalo en imágenes de resonancia magnética usando contornos activos* [Tesis de maestría, UNAM].
- Mendoza, L. (2001). *Estudio del consumo energético y emisiones de CO₂ para la industria de la celulosa y el papel en el periodo 1965 - 2001* [Tesis de maestría, UNAM].
- Morales, C. (2024). Redes neuronales convolucionales para clasificación de componentes electrónicos. *Revista de integración*, 1(11), 64-75.
- Rocha, L., Gadotti, G., Bernardy, R., Pinheiro, R., & Monteiro, R. (2023). Mineração de dados no ranqueamento de lotes de sementes de sorgo. *Caatinga*, 471-478.
- Santamaría, L. (2019). *Reconocimiento de patrones en imágenes médicas por medio de redes neuronales convolucionales* [Tesis de maestría, Benemérita Universidad Autónoma de Puebla].
- TAPPI. (1993). *Consistency (concentration) of pulp suspensions* (T. A. of the Paper & P. Industry, Eds.) [T 240 om-93].


Valmet. (2021). *Valmet Optical Consistency Measurement OC2R – Product Guide* (V. Corporation, Ed.) [Acceso: 2025-05-29]. <https://valmet.my.site.com/solutionfinder/file-preview?contentDocumentId=06958000005FebWAAS>


ANEXOS


Anexo A. Planos del proyecto


La página se ha dejado en blanco intencionalmente debido al tamaño de los planos









A4

