

Aplicación de redes neuronales en el subproceso de preparación de la pulpa para las hojas A4

Application of neuronal networks in the A4 leaf pulp preparation subprocess

Bryan Eduardo Alarcón Bazurto^{1*}

¹Universidad Estatal Península de Santa Elena. Facultad de Sistemas y Telecomunicaciones
Santa Elena-Santa Elena. Ecuador

ORCID: <https://orcid.org/0000-0002-8396-378X>

Correo: alarconbazurtobryan@gmail.com

Carlos Alberto Saldaña Enderica²

ORCID: <https://orcid.org/0000-0002-5867-1734>

²Universidad Estatal Península de Santa Elena. Facultad de Sistemas y Telecomunicaciones en Electrónica y Automatización.
La Libertad - Santa Elena. Ecuador.

Correo: csaldana@upse.edu.ec

*Autor para correspondencia: alarconbazurtobryan@gmail.com

Resumen

El artículo se enfoca en la aplicación innovadora de Redes Neuronales (RNA) en el subproceso de preparación de pulpa de hojas A4 en la industria papelera, con el objetivo de mejorar la eficiencia operativa y abordar desafíos específicos relacionados con el proceso de elaboración del producto. La RNA en construcción se basa en el algoritmo de retro propagación en un proceso de aprendizaje supervisado.

Para el diseño de la RNA, se recopiló una extensa base de datos que abarca variables cruciales para el subproceso, como la composición química de las materias primas, condiciones operativas y características físicas y químicas de la pulpa resultante. Los parámetros de inicialización se obtienen de un conjunto de datos tabulados en Excel. En cuanto a la topología de la RNA, se destaca la dificultad para establecer reglas específicas sobre el número de capas y neuronas ocultas necesarias. El entrenamiento de la RNA implica un proceso de aprendizaje supervisado con un agente externo, utilizando pesos sinápticos predefinidos. La red se presenta como parte de un proceso de aprendizaje con un conjunto de pares entrada-salida. Se emplean algoritmos de optimización y técnicas de regularización durante el entrenamiento para mejorar la generalización del modelo y evitar el sobreajuste.

Palabras claves: Redes Neuronales, industria papelera, proceso de aprendizaje, datos tabulados, aprendizaje, entradas y salidas.

Abstract

The article focuses on the innovative application of Neural Networks (RNA) in the A4 sheet pulp preparation subprocess in the paper industry, with the aim of improving operational efficiency and addressing specific challenges related to product uniformity and quality. The ANN under construction is based on the back propagation algorithm in a supervised learning process.

For the design of the ANN, an extensive database was compiled that covers crucial variables for the





subprocess, such as the chemical composition of the raw materials, operating conditions and physical and chemical characteristics of the resulting pulp. The initialization parameters are obtained from a set of 200 data tabulated in Microsoft Excel. Regarding the topology of the ANN, the difficulty in establishing specific rules on the number of layers and hidden neurons necessary is highlighted. ANN training involves a supervised learning process with an external agent, using predefined synaptic weights. The network is presented as part of a learning process with a set of input-output pairs. Optimization algorithms and regularization techniques are used during training to improve model generalization and avoid overfitting.

Keywords: *Neural Networks, paper industry, learning process, tabulated data, learning, inputs and outputs.*

I. Introducción

En la era actual, marcada por la digitalización y la creciente conciencia ambiental, la industria papelera busca constantemente métodos innovadores que no solo mejoren la eficiencia de sus procesos, sino que también reduzcan su impacto medioambiental. Dentro de este contexto, el presente artículo se centra en la aplicación pionera de las Redes Neuronales en el crucial subproceso de preparación de la pulpa de hojas A4, con el objetivo de optimizar la producción, minimizar residuos y elevar los estándares de sostenibilidad en esta industria fundamental [1].

La preparación de la pulpa es un componente esencial en la fabricación del papel, y la transición hacia hojas A4 introduce desafíos específicos relacionados con la uniformidad y calidad del producto final. La complejidad de este subproceso, caracterizado por la variabilidad en las materias primas y las condiciones de operación, hace que sea ideal para la implementación de técnicas avanzadas como las Redes Neuronales [2].

En este artículo, se revisarán los antecedentes teóricos de las Redes Neuronales, destacando su capacidad para modelar relaciones no lineales y adaptarse a patrones complejos presentes en conjuntos de datos dinámicos. Se explorarán estudios previos que han utilizado Redes Neuronales en el contexto de la industria papelera, proporcionando un marco conceptual para la aplicación específica en el subproceso de preparación de la pulpa de hojas A4 [3].

A través de este estudio, se aspira no solo a optimizar el rendimiento del subproceso de preparación de la pulpa de hojas A4, sino también a establecer un precedente para la incorporación exitosa de tecnologías de inteligencia artificial en la industria papelera. [4]

La aplicación de Redes Neuronales en este contexto no solo representa un avance técnico, sino un paso significativo hacia la construcción de procesos industriales más eficientes y sostenibles en armonía con las demandas del siglo XXI. A4 [5].

II. Materiales y métodos

2.1. Diseño de la RNA

La red multicapa que se está construyendo utiliza conexiones feedforward y se basa en el algoritmo de retro propagación. Esto se hace mediante un proceso de aprendizaje supervisado, por lo que se requiere un conjunto de datos de entrenamiento para especificar la salida que la red debe producir en respuesta a la





entrada dada [6]. Para esto se recopiló una extensa base de datos que abarca múltiples variables relevantes para el subproceso de preparación de la pulpa de hojas A4 [7].

2.2. Base de datos de la RNA

Se recopiló una extensa base de datos que abarca múltiples variables relevantes para el subproceso de preparación de la pulpa de hojas A4. Estas variables incluyen, pero no se limitan a, la composición química de las materias primas, las condiciones de operación del proceso, y las características físicas y químicas de la pulpa resultante [8]. Los parámetros de inicialización de la RNA se obtienen de un conjunto de 200 datos que fueron tabulados en Microsoft Excel [9].

2.3. Topología de la RNA

No es posible establecer reglas específicas para definir el número de capas ocultas y neuronas ocultas necesarias en una red neuronal para abordar un problema particular. Por lo general, el tamaño de las capas de entrada y salida se determina según la naturaleza de la aplicación en cuestión [10]. La eficiencia de aprendizaje y generalización de la red está influenciada por la cantidad de neuronas ocultas, y en muchos casos, una sola capa oculta es suficiente para lograr la convergencia de la solución. [11]

Sin embargo, hay situaciones en las que resolver un problema puede ser más efectivo con más de una capa oculta. Por lo tanto, la determinación del número óptimo de capas y neuronas ocultas se realiza a través de la experimentación [12].

2.4. Entrenamiento de la RNA

El proceso de aprendizaje supervisado de las redes neuronales artificiales (RNA) implica un entrenamiento controlado por un agente externo, que busca información para producir un resultado deseado fortaleciendo las conexiones [13]. Una forma de hacerlo es asignar pesos sinápticos predefinidos.

Por tanto, una red neuronal artificial se presenta como parte de un proceso de aprendizaje con un conjunto de pares entrada-salida, instancia formada por una entrada y su correspondiente salida. [14]

El modelo de Redes Neuronales se entrenó utilizando el conjunto de entrenamiento y se validó en el conjunto de validación para evitar el sobreajuste. Se emplearon algoritmos de optimización y técnicas de regularización para mejorar la generalización del modelo [15].

III. Resultados

Las entradas configuradas en la Red Neuronal Artificial (RNA) se restringen de manera exclusiva al flujo de información, desempeñando un papel fundamental en la transmisión de datos hacia el sistema. Las capas ocultas y de salida, por otro lado, asumen la responsabilidad del procesamiento de información correspondiente. Esta estrategia posibilita una clara delimitación de funciones dentro del sistema, donde las entradas gestionan la información entrante, y las capas ocultas y de salida ejecutan el procesamiento necesario para obtener los resultados deseados.

Mediante el software Matlab, es posible examinar la estructura detallada de la RNA, como se ilustra en la Figura 1. Esta representación visual proporciona una visión detallada de las capas y conexiones que constituyen la red, ofreciendo información crucial sobre la disposición de las capas de entrada, ocultas y de





salida, así como las conexiones sinápticas entre ellas. Este análisis estructural en Matlab facilita una comprensión profunda de la arquitectura de la red, permitiendo ajustes y optimizaciones precisas para mejorar su desempeño y adaptarla de manera eficaz a los requisitos específicos del proceso de preparación de la pulpa de hojas tamaño A4.

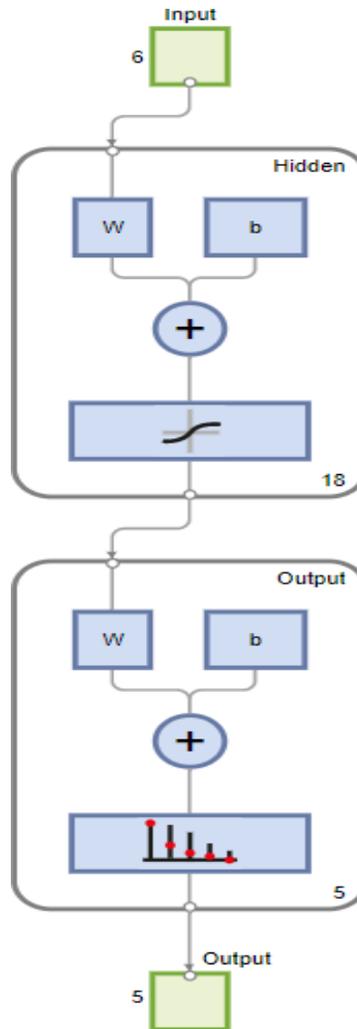


Figura 1. Estructura de la RNA diseñada

La figura 2 exhibe un histograma de errores derivados de un modelo de red neuronal tras 618 épocas de entrenamiento. Este histograma clasifica los errores en 20 compartimientos (bins), calculando el error como la discrepancia entre las salidas de la red y los valores objetivos reales. A continuación, se proporciona una interpretación detallada:

- Eje X (Errores = Targets - Outputs): Representa la magnitud del error, asignando cada compartimiento a un rango específico de error. El punto central, identificado como "Zero Error", señala el punto en el que no existe diferencia entre las predicciones y los valores reales.

Eje Y (Instancias): Indica el número de instancias (o predicciones) que se encuentran en cada rango de error.





- Colores: Tres colores distintos representan tres conjuntos de datos diferentes:
- Azul (Entrenamiento): Muestra la distribución de errores en el conjunto de entrenamiento.
- Verde (Validación): Refleja la distribución de errores en el conjunto de validación.
- Rojo (Prueba): Exhibe la distribución de errores en el conjunto de prueba.

En cuanto al análisis del histograma:

- La barra vertical amarilla señala la posición de "Zero Error". La proximidad de las barras de colores a esta línea amarilla indica la precisión del modelo.
- La mayoría de las instancias en los conjuntos de entrenamiento, validación y prueba se concentran en el compartimiento central (alrededor de "Zero Error"), sugiriendo un rendimiento destacado de la red y una alta precisión en la mayoría de las predicciones.
- La similitud en la altura de las barras azul, verde y roja en el compartimiento de "Zero Error" indica un comportamiento consistente del modelo en todos los conjuntos de datos, señalando que el modelo generaliza bien y no padece de sobreajuste o subajuste significativo.

Esta distribución estrecha y centrada de errores indica un modelo bien entrenado capaz de realizar predicciones precisas tanto en datos observados (entrenamiento) como en datos no observados (validación y prueba). No obstante, es crucial verificar la consistencia y robustez de estos resultados mediante pruebas adicionales y posiblemente mediante validación cruzada, evitando conclusiones erróneas basadas en un conjunto de datos específico o una única iteración de entrenamiento.

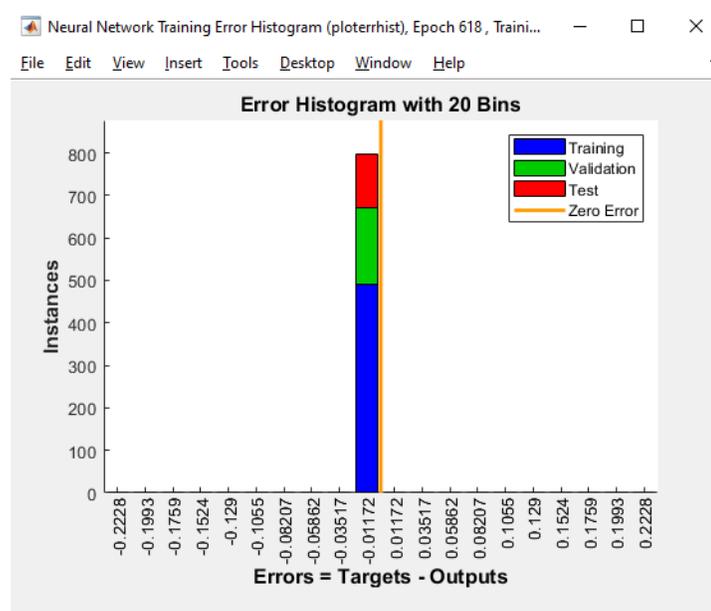


Figura 2. Histograma de errores.

3.1. Rendimiento del modelo

La comparación del rendimiento de los conjuntos de datos de entrenamiento, prueba y validación con el resultado requerido se muestra en la Figura 3. Las muestras utilizadas para la validación se utilizan





para medir la generalización de la red y el entrenamiento se detiene cuando este se complete.

La figura 3 muestra el desempeño de un modelo de red neuronal durante su entrenamiento a lo largo de 618 épocas. Aquí hay una interpretación detallada:

- **Ejes:** El eje vertical (Y) representa el error cuadrático medio (Mean Squared Error, MSE) en una escala logarítmica, lo cual es útil para ver claramente las mejoras en el desempeño cuando los valores del error son muy pequeños o varían en un amplio rango. El eje horizontal (X) muestra el número de épocas de entrenamiento.
- **Curvas de Error:** Hay tres curvas que representan el error de entrenamiento (azul), validación (verde) y prueba (rojo) a lo largo de las épocas:
 - **Entrenamiento (Azul):** Muestra cómo el modelo mejora su ajuste a los datos de entrenamiento a medida que pasa el tiempo. El descenso continuo indica que el modelo está aprendiendo y mejorando su predicción en los datos de entrenamiento.
 - **Validación (Verde):** Representa cómo el modelo generaliza a un conjunto de datos que no se utiliza durante el entrenamiento pero que sirve para ajustar hiperparámetros y prevenir el sobreajuste. Esta curva es la más importante porque indica cómo el modelo se desempeñará con datos que no ha visto antes.
 - **Prueba (Rojo):** Muestra el error del modelo en un conjunto de datos de prueba que no se utiliza durante el entrenamiento ni la validación. Esta curva proporciona la evaluación final de cómo el modelo se desempeñará en el mundo real.
- **Mejor Desempeño de Validación:** La línea punteada y el círculo en la curva de validación señalan el mejor desempeño que se ha alcanzado durante el entrenamiento, que es un MSE de aproximadamente 0.00059495 en la época 618. Este valor extremadamente bajo del MSE sugiere que el modelo ha logrado una precisión muy alta en el conjunto de validación.
- **Análisis de Overfitting:** No parece haber overfitting significativo, ya que las curvas de entrenamiento y validación están cerca una de la otra y la curva de prueba sigue un patrón similar. Esto es un buen indicador de que el modelo generaliza bien.
- **Consideraciones Adicionales:**
 - La escala logarítmica puede exagerar las diferencias entre las curvas cuando el error es bajo.
 - Un MSE cercano a cero, como se ve en la curva de validación, podría ser indicativo de un modelo que está muy bien ajustado o podría ser un signo de que los datos son muy simples, el modelo es muy complejo, o hay un error en el proceso de validación o cálculo del error.
 - Es inusual ver un MSE tan bajo como el reportado (0.00059495), lo cual podría deberse a datos muy predecibles, una métrica de error incorrecta, un conjunto de validación muy pequeño, o incluso un error en la implementación.



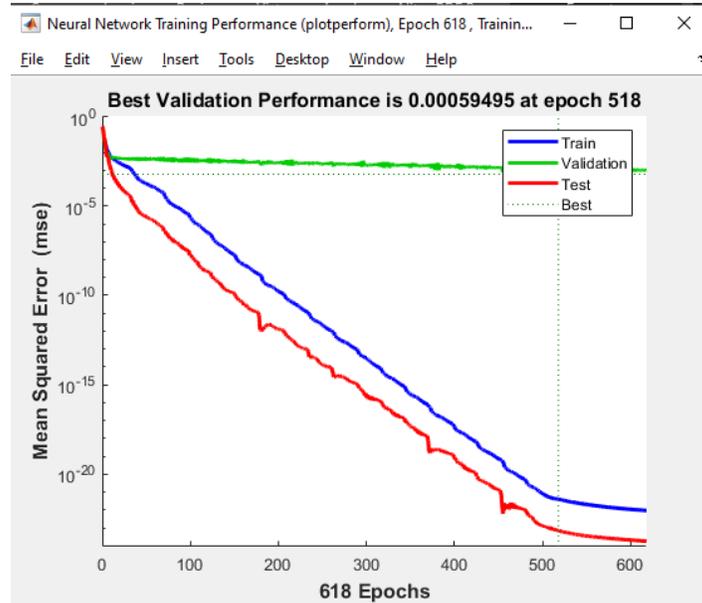


Figura 3. Rendimiento del proceso de entrenamiento de la RNA.

La representación gráfica de la figura 4 exhibe tres gráficos distintos que son comunes al entrenar redes neuronales y evaluar su estado de entrenamiento:

1. Gráfico del Gradiente: El primer gráfico ilustra el gradiente a lo largo del proceso de entrenamiento. El gradiente refleja la pendiente de la función de pérdida o error con respecto a los parámetros del modelo, siendo crucial para la optimización (ajuste de los parámetros). En este caso, el gradiente muestra una disminución constante a lo largo de las épocas, alcanzando un valor muy bajo en la época 618 (aproximadamente $4.788e-22$), indicando positivamente que el modelo se acerca a un punto mínimo de error.

2. Gráfico de Mu: El segundo gráfico probablemente representa la tasa de aprendizaje (μ) durante el entrenamiento. En algunos algoritmos de optimización, como los adaptativos o los que implementan métodos de momentum, 'mu' puede variar para ajustar la velocidad de actualización de los parámetros del modelo. Un 'mu' de $1e-20$ es extremadamente bajo, sugiriendo que el algoritmo de aprendizaje ha convergido y está realizando ajustes muy pequeños a los parámetros del modelo. Esto también podría indicar que el entrenamiento está llegando a su conclusión, ya que los ajustes son tan finos que no se anticipa un cambio significativo en los parámetros con más entrenamiento.

3. Gráfico de Verificaciones de Validación: El tercer gráfico representa las "verificaciones de validación". En el contexto del entrenamiento de redes neuronales, esto generalmente se refiere a un mecanismo de "early stopping", donde el entrenamiento puede detenerse si el rendimiento en el conjunto de validación no mejora después de un cierto número de épocas. Un contador registra cuántas veces el modelo no ha mejorado durante el entrenamiento. En este gráfico, observamos que el contador está en cero en la época 618, indicando que el modelo no ha activado el mecanismo de early stopping y que posiblemente continúa mejorando o, al menos, no ha deteriorado su rendimiento en el conjunto de validación.





En base a estos tres gráficos, se sugiere que el modelo de red neuronal está convergiendo eficazmente durante el entrenamiento. El gradiente disminuye, la tasa de aprendizaje es baja y no ha sido necesario detener el entrenamiento anticipadamente debido a la falta de mejoras en el conjunto de validación. Esto apunta a que el modelo está aprendiendo de manera efectiva a partir de los datos suministrados.

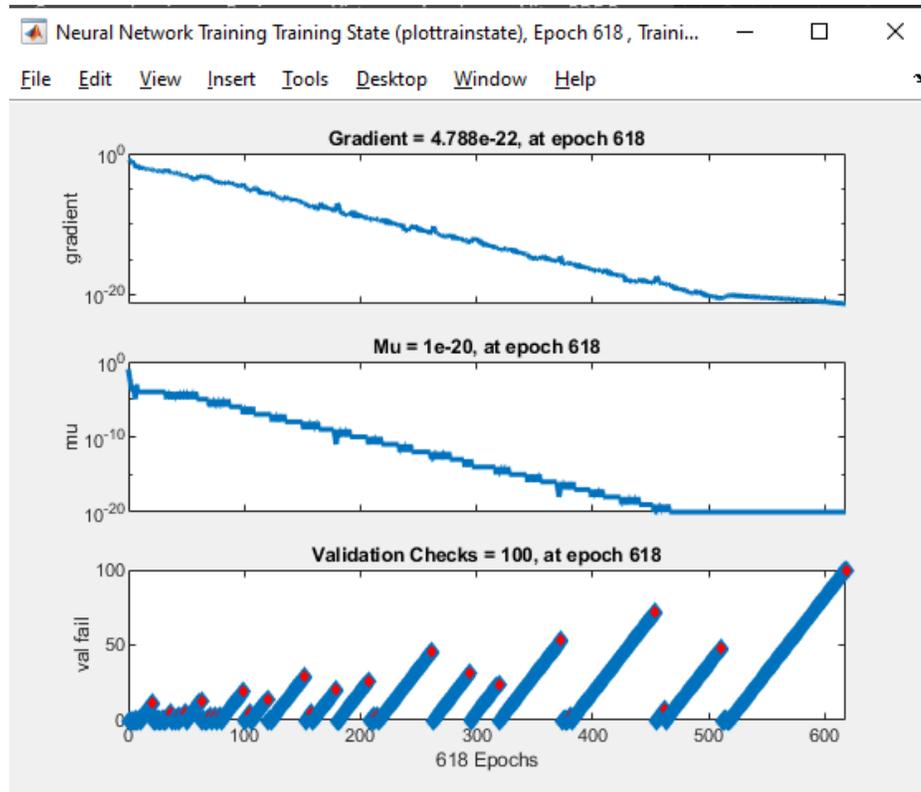


Figura 4. Estado de entrenamiento de la RNA.

3.2. Comparación RNA – Programación TIA PORTAL

En las Tabla 1 y Tabla 2 se expone de manera detallada el funcionamiento del proceso de preparación de la pulpa destinado a la producción de hojas A4, específicamente implementado en el entorno del software TIA PORTAL. La tabla documenta exhaustivamente las diversas etapas y componentes involucrados en este proceso, incluyendo tanto las entradas que alimentan información al sistema como los actuadores que ejecutan acciones específicas en respuesta a las señales recibidas.

Es importante destacar que el software TIA PORTAL, al ser la plataforma central para la ejecución y supervisión de este proceso, ha asumido un papel trascendental. La integración de redes neuronales en este contexto ha sido instrumental para potenciar la eficacia del subproceso de preparación de la pulpa de hojas A4.





Tabla 1. Entradas del proceso de preparación de la pulpa en TIA PORTAL

Modo manual	Sensor de activación	Tiempo de lavado	Temperatura	Tiempo de cocción	Tiempo de lavado de la pulpa
1	1	1	0	0	1
1	1	1	1	0	0
1	1	1	1	1	1
1	1	1	1	1	1

Tabla 2. Actuadores del proceso de preparación de la pulpa en TIA PORTAL

Proceso de lavado	Calentar horno	Calentador pulpa	Lavado de la pulpa	Fin del proceso
1	1	1	0	0
1	1	1	1	0
1	1	1	1	1
1	1	1	1	1

3.3. Salidas resultantes de la RNA

En la Tabla 3, se detallan las salidas generadas al ejecutar la Red Neuronal Artificial (RNA). Cada salida se presenta en formato binario, expresada como 0 o 1, lo que indica de manera clara y concisa la ejecución y resultados de la red en cada instancia. Este formato binario encapsula la respuesta de la RNA, donde el valor de 1 se interpreta como la confirmación de que cierto proceso o condición está teniendo lugar, mientras que el valor de 0 sugiere lo contrario.

Tabla 3. Salidas resultantes de la RNA.

Proceso de lavado	Calentar horno	Calentador pulpa	Lavado de la pulpa	Fin del proceso
1	0	0	0	0
0	1	0	0	0
0	0	1	0	0
0	0	0	1	0
0	0	0	0	1





3.4. Variables lógicas del proceso

Tabla 4. Variables (simplificadas) del proceso de la preparación de la pulpa.

NOMBRE	Variable
Modo manual	MM
Sensor de activación	SA
Tiempo de lavado	TL
Temperatura	T
Tiempo de cocción	TC
Tiempo de lavado de la pulpa	TLP
Proceso de lavado	PL
Calentar horno	CH
Calentador pulpa	CP
Lavado de la pulpa	LP
Fin del proceso	FP

Variables del proceso de la preparación de la pulpa

- $PL = MM * SA * TL * T * \bar{T}\bar{C} * \bar{T}\bar{L}\bar{P}$
- $CH = MM * SA * TL * T * \bar{T}\bar{C} * \bar{T}\bar{L}\bar{P}$
- $CP = MM * SA * TL * T * TC * \bar{T}\bar{L}\bar{P}$
- $LP = MM * SA * TL * T * TC * TLP$
- $FP = MM * SA * TL * T * TC * TLP$

3.5. Validación del funcionamiento

Validación 1. TIA PORTAL - RNA

Para empezar con la comprobación se tomará de referencia la tabla de verdad del funcionamiento del proceso en TIA PORTAL correspondiente a las Tablas 1 y 2. Se va a comprobar la primera combinación en la cual dará como resultado el proceso de lavado, el cual se accionará si el modo manual esta en 1 y el sensor de activación de igual forma.

Validación 2. RNA

En la tabla 1. Podemos observar las combinaciones que representan el accionamiento del proceso, el cual vamos a corroborar que tanto la RNA como el proceso en TIA PORTAL funcionen de igual forma. Se ingresan los datos de “1 1 0.5 0 0 0” los cuales hacen referencia a que se acciona el modo manual y el sensor de peso y se procede a mostrar la salida del proceso de lavado como observamos en la tabla 2.





```
260 %%
261
262 %COMPROBAR MI RED NEURONAL
263 %red(vector caracteristico para comprobar funcionamiento)
264 red([1 1 0.5 0 0 0]')
265
266 %%
```

Command Window

New to MATLAB? See resources for [Getting Started](#).

```
1.0000
0.0000
0.0000
0.0000
0.0000
```

Figura 5. Funcionamiento de la RNA.

La Tabla 3, al presentar respuestas en forma de 0 y 1, proporciona una representación binaria que refleja la activación o desactivación de ciertos eventos o condiciones en el sistema, gracias al procesamiento de la RNA. Esta forma de respuesta se asemeja a la lógica binaria inherente a los actuadores, como se detalla en la Tabla 2, donde ciertos valores indican la ejecución de acciones específicas dentro del TIA PORTAL.

La consistencia entre las respuestas de la RNA y las acciones de los actuadores resalta la sincronización efectiva entre la toma de decisiones basada en inteligencia artificial y la ejecución de acciones físicas o lógicas en el entorno de control industrial.

Validación 3. TIA PORTAL - RNA

En la fase de verificación del cierre completo del proceso, se establece un criterio específico en el cual las entradas deben estar en un estado binario de 1 para que la salida de la Red Neuronal Artificial (RNA) indique el término exitoso del proceso. Este criterio se respalda en la lógica establecida en las Tablas 1 y 2, donde se detallan las configuraciones de entradas y las acciones ejecutadas por los actuadores en el software TIA PORTAL.

En la Tabla 1 se describe minuciosamente el funcionamiento del proceso de preparación de pulpa, incluyendo las distintas entradas que alimentan información al sistema. La condición de que todas las entradas estén en un estado binario de 1 actúa como un marcador clave para determinar que todas las fases requeridas del proceso se han completado de manera satisfactoria.

Validación 4. RNA

En el contexto de la Tabla 1, al ingresar los valores específicos [1 1 0 180 0 20] en nuestra Red Neuronal Artificial (RNA), se establece una configuración particular para la ejecución del proceso. Esta entrada se descompone en distintos parámetros, donde "1 1" puede representar, por ejemplo, el modo manual y la activación del sensor de peso, mientras que los valores numéricos restantes, como "180," "0," y "20," están asociados con otros aspectos del proceso, como duraciones, velocidades u otros valores relevantes.





En la Tabla 2, se documenta la salida resultante del proceso asociado a la mencionada combinación de entrada. En este caso específico, se espera que la salida refleje el estado final del proceso, indicando el cumplimiento de las condiciones necesarias para la conclusión exitosa del mismo.

```
260 %%  
261  
262 %COMPROBAR MI RED NEURONAL  
263 %red(vector caracteristico para comprobar funcinamiento)  
264 red([1 1 0 180 0 20]')  
265  
266 %%
```

Command Window

New to MATLAB? See resources for [Getting Started](#).

```
0.0000  
0.0000  
0.0000  
0.0000  
1.0000
```

Figura 6. Comprobación en la RNA del Fin del proceso.

La Figura 6 presenta de manera gráfica la correspondencia entre las respuestas obtenidas de la Red Neuronal Artificial (RNA) y las respuestas generadas por el software TIA PORTAL. Esta representación gráfica es respaldada por la observación y comparación de los resultados detallados en la Tabla 3. La figura destaca la coherencia y similitud entre ambas fuentes de información, reforzando la idea de que tanto la RNA como el programa del PLC en TIA PORTAL están proporcionando resultados idénticos.

Al analizar la Tabla 3, se confirma que las respuestas obtenidas de la RNA coinciden exactamente con las respuestas generadas por el TIA PORTAL.

IV. Conclusiones

La aplicación de Redes Neuronales Artificiales (RNA) para simular la lógica combinatorial en la preparación de pulpa de hojas A4 en la industria papelera representa un avance técnico significativo, optimizando la eficiencia operativa y la calidad del producto. Utilizando algoritmos de retropropagación en un aprendizaje supervisado y una base de datos extensa, se aborda la compleja tarea de determinar la topología óptima de la red, mientras se integra con sistemas de control industrial como TIA PORTAL. A pesar de los desafíos en la configuración de la red y la necesidad de técnicas de regularización para evitar el sobreajuste, la RNA muestra un potencial considerable para mejorar los procesos industriales y establecer un precedente para futuras innovaciones y aplicaciones de inteligencia artificial en la industria papelera y más allá.

Sin embargo, si el problema es bien definido y la lógica de operación es clara, la lógica combinatorial en un PLC puede ser la opción más sencilla y efectiva. pero para problemas complejos con patrones no lineales y datos variables, una RNA puede ofrecer una solución más robusta y adaptable, aunque a un costo mayor y con requisitos técnicos más complejos. La decisión final debe basarse en una evaluación detallada de las necesidades específicas del proyecto y los recursos disponible

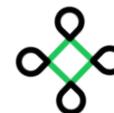




Referencias

- [1] M. C. Cárdenas, «Edu.pe,» 2017. [En línea]. Available: https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/1406/Calder%20c3%b3n_CM-SD.pdf?sequence=4&isAllowed=y.
- [2] F. Izaurieta y C. Saavedra, «Cloudfront.net,» 2000. [En línea]. Available: https://d1wqtxts1xzle7.cloudfront.net/36957207/Redes_neuronales-libre.pdf?1426217722=&response-content-disposition=inline%3B+filename%3DRedes_Neuronales_Artificiales.pdf&Expires=1703044968&Signature=aC28BZQRJzQz9we7ItJv1bBJY8PkSTru55kzaBK4W7ggvhSn14OhQ9TS.
- [3] R. Salas, «Cloudfront.net,» 2004. [En línea]. Available: https://d1wqtxts1xzle7.cloudfront.net/50358783/Redes_Neuronales_Artificiales-libre.pdf?1479332869=&response-content-disposition=inline%3B+filename%3DRedes_Neuronales_Artificiales.pdf&Expires=1703045104&Signature=NuS5H50gF6ACOkjQmmlQhtZ1Qy4NaCF6QN-1vWxjBla.
- [4] B. Velázquez, «Producción de papel artesanal a partir de los residuos de la corona de la piña (Ananás Comosus) generados en el mercado Unicachi - Comas, 2018,» 2018. [En línea]. Available: <https://repositorio.ucv.edu.pe/handle/20.500.12692/57367>.
- [5] M. Díaz, R. Reina, G. Santana y M. Morales, 13 Mayo 2023. [En línea]. Available: <https://rci.cujae.edu.cu/index.php/rci/article/view/870>.
- [6] N. García, «Diseño de redes neuronales artificiales para el mercado inmobiliario. Aplicación a la ciudad de Albacete,» 2004. [En línea]. Available: <https://investigacion.usc.es/documentos/5d1df66829995204f766b1a5>.
- [7] P. Ponce, «Inteligencia Artificial con Aplicaciones a la Ingeniería,» Marcombo, 2011. [En línea]. Available: https://books.google.com.ec/books?id=myyQpwAACAAJ&dq=Inteligencia+Artificial+con+Aplicaciones+a+la+Ingenier%C3%ADa&hl=es&sa=X&ved=0ahUKEwjW_7bdw8LbAhUDyVMKHdueCC4Q6AEIJTAA.
- [8] E. Chafla, «Influencia de los Algoritmos de Entrenamiento de RNAs en la Predicción del Nivel de Embalse de Agua en una Estación Hidroeléctrica,» 2019. [En línea]. Available: http://perspectivas.esPOCH.edu.ec:8081/index.php/RCP_ESPOCH/article/view/20.
- [9] M. Juan, «Redes Nueronales Artificiales aplicadas al análisis de datos,» 2002. [En línea]. Available: <https://www.tesisenred.net/bitstream/handle/10803/9441/tjmm1de1.pdf?sequence=1>.
- [10] Z. Francisco, «ENTRENAMIENTO DE MODELOS DE LENGUAJE CONEXIONISTAS CON GRANDES VOCABULARIOS,» 2006. [En línea]. Available: http://jth2006.unizar.es/finals/4jth_165.pdf.
- [11] T. Héctor, «Revista Facultad de Ingeniería Universidad de Antioquia,» 2006. [En línea]. Available: http://www.scielo.org.co/scielo.php?pid=S0120-62302006000400014&script=sci_arttext.





- [12] B. David, «Topología de una RNA para calcular la cinemática inversa del Puma 560 para aplicaciones en tiempo real,» 2019. [En línea]. Available: https://rcs.cic.ipn.mx/2019_148_8/Topologia%20de%20una%20RNA%20para%20calcular%20la%20cinematica%20inversa%20del%20Puma%20560%20para%20aplicaciones.pdf.
- [13] J. Carbonell, «Aplicación de diferentes arquitecturas de RNA sobre datos de paquetes de red en Matlab con y sin reducción de características.,» 2020. [En línea]. Available: https://www.researchgate.net/profile/Judith-Mca/publication/266613649_Aplicacion_de_diferentes_arquitecturas_de_Redes_Neuronales_Artificiales_sobre_datos_de_paquetes_de_red_en_Matlab_con_y_sin_reduccion_de_caracteristicas/links/543535170cf2bf1f1f282a02/Ap.
- [14] S. Tostado, «Implementación de Algoritmos de Inteligencia Artificial para el Entrenamiento de Redes Neuronales de Segunda Generación,» 2016. [En línea]. Available: <https://www.jovenesenlaciencia.ugto.mx/index.php/jovenesenlaciencia/article/view/715>.
- [15] J. Rojas, «Algoritmo meta-heurístico Firefly aplicado al pre-entrenamiento de redes neuronales artificiales,» 2018. [En línea]. Available: http://scielo.sld.cu/scielo.php?pid=S2227-18992018000100002&script=sci_arttext.

