



2025 | **16-20**
GIJÓN | **JUNIO**

9º CONGRESO FORESTAL ESPAÑOL

9CFE-1849

Actas del Noveno Congreso Forestal Español
Edita: **Sociedad Española de Ciencias Forestales. 2025.**
ISBN: **978-84-941695-7-1**

Organiza





Optimización de la resistencia a tracción, alargamiento y estallido de pastas celulósicas mediante su modelización con redes neuronales artificiales a partir de sus parámetros de fabricación

GARCÍA IRUELA, A. (1), GARCÍA FERNÁNDEZ, F. (2), LÓPEZ ÁLVAREZ, J. (1), GARCÍA ESTEBAN, L. (2), DE PALACIOS DE PALACIOS, P. (2)

(1) Departamento de Ingeniería y Gestión Forestal y Ambiental. ETS de Ingeniería de Montes, Forestal y del Medio Natural. Universidad Politécnica de Madrid. Ciudad Universitaria S/N. 28040 Madrid.

(2) Departamento de Sistemas y Recursos Naturales. ETS de Ingeniería de Montes, Forestal y del Medio Natural. Universidad Politécnica de Madrid. Ciudad Universitaria S/N. 28040 Madrid.

Resumen

Unas de las propiedades más importantes dentro de control de producción en fábrica de la hoja de papel es el alargamiento, la resistencia a tracción y su resistencia al estallido ya que son indicadores de la cohesión de la hoja. Los ensayos para determinar estas propiedades, dependientes de los parámetros de fabricación, carecen de la inmediatez necesaria para su aplicación en tiempo real en fábrica. Para solventar este problema se han modelizado dichas propiedades a partir de los parámetros de producción mediante el uso de una red neuronal artificial (ANN) consiguiendo un simulador de la línea de producción. Para ello se han ensayado 288 formetas de las cuales se han tomado datos del tipo de fibra, tiempo de refino, gramaje y espesor. Los ensayos realizados siguieron las normas UNE de formación de hojas de laboratorio, gramaje, ensayo a tracción y estallido. Las redes desarrolladas han obtenido en el conjunto de comprobación coeficientes de correlación superiores a 0,85, lo que las avala para su uso en el control diario de la producción, y han permitido la obtención de una serie de gráficas 3D con las que optimizar los parámetros de producción.

Palabras clave

Inteligencia artificial, aprendizaje automático, celulosa, caracterización.

1. Introducción

La industria de la fabricación de papel y sus derivados constituye uno de los sectores industriales más relevantes y evolucionados a nivel global. Con presencia en más de 100 países, esta industria es liderada por grandes productores como Estados Unidos, Brasil, Canadá, China, Japón, Suecia, Finlandia, Alemania y Francia (FAO, 2022). Según datos de FAO (2022), durante 2020 se alcanzó una producción y consumo mundial de 186 millones de toneladas de pasta de celulosa. Asimismo, la producción de papel y cartón se situó en 400,9 millones de toneladas, con un consumo de 400,8 millones de toneladas.

En el contexto europeo, España destaca como uno de los principales actores en



la industria papelera. Específicamente, ocupa el quinto lugar como fabricante de celulosa, el sexto como productor de papel y es el mayor reciclador de papel después de Alemania e Italia (ASPAPPEL, 2024). En 2023, España registró una producción de 1,60 millones de toneladas de celulosa y 6 millones de toneladas de papel y cartón. Durante el periodo 2000-2020, la producción y el consumo de celulosa en España oscilaron entre 1,6 y 2,1 millones de toneladas, lo que representó aproximadamente el 5% de la producción europea (ORTUÑO y GONZÁLEZ GONZÁLEZ, 2021).

La cadena de valor del sector papelero abarca no solo a los fabricantes de celulosa, papel y cartón, sino también a impresores, editores, empresas de recuperación de papel y cartón, así como a compañías del sector de transformación, entre ellas fabricantes de envases, embalajes y manipulados de cartón ondulado, bolsas, sobres, carpetas y otros productos. En España, este ecosistema industrial comprende 17.300 empresas, genera 369.036 empleos (de los cuales 16.964 son directos) y alcanza una facturación total de 48.471 millones de euros en la cadena de valor, siendo 5.261 millones de euros exclusivos del sector de celulosa y papel (ASPAPPEL, 2021; ASPAPPEL, 2024). En términos económicos, representa el 4,5% del PIB español, el 8,8% de la facturación industrial, el 2% del empleo total del país y el 18,5% del empleo industrial, además de contribuir con un 1,8% a la recaudación fiscal y un 13,2% al valor añadido de la industria (ASPAPPEL, 2021).

Desde una perspectiva histórica, el papel ha desempeñado un rol fundamental en el desarrollo cultural de la humanidad, y, pese a la digitalización, sigue siendo esencial en diversas áreas como la comunicación, el embalaje y la educación. La continuidad de su relevancia futura depende de su capacidad para innovar en el desarrollo de productos que respondan a las crecientes demandas de rendimiento y sostenibilidad. Esto implica optimizar los procesos de producción para que sean más eficientes, respetuosos con el medio ambiente y económicos en el uso de recursos. En este contexto, la colaboración interdisciplinaria entre ciencias básicas, ingeniería y economía es esencial para abordar los desafíos del sector (LEVLIN & SÖDERHJELM, 1999).

El control de calidad ocupa un lugar central en la industria de la pasta de celulosa y el papel, garantizando la producción de materiales que cumplan con las expectativas del mercado. Estos productos abarcan aplicaciones tan diversas como papel tissue, periódicos, revistas, embalajes y cartones, destacando la importancia de mantener altos estándares de calidad para asegurar la competitividad en un mercado globalizado (GARCÍA IRUELA et al., 2023).

La evaluación de las propiedades físico-mecánicas de las pastas y papeles constituye el primer paso en los procesos de control de calidad en las plantas de producción (SIERRA GRANADOS et al., 1998; LEVLIN & SÖDERHJELM, 1999; HOLIK, 2006; LÓPEZ ÁLVAREZ et al., 2011). Las propiedades básicas del papel incluyen contenido de humedad, gramaje, espesor, densidad y volumen específico, todas fundamentales para caracterizar el material (LEVLIN & SÖDERHJELM, 1999; HOLIK, 2006; EK et al., 2009b).



Uno de los índices más importantes para el conocimiento de las características de un papel o cartón es su resistencia cuando se le somete a tracción (SIERRA GRANADOS et al., 1998; LEVLIN & SÖDERHJELM, 1999; HOLIK, 2006; EK et al., 2009a, 2009b). La norma UNE-EN ISO 1924-2 (AENOR, 2009) define la resistencia a la rotura por tracción como la resistencia límite de una probeta de papel o cartón sometida a una fuerza creciente de tracción en cada extremo. Esta resistencia límite se denomina carga de rotura. La resistencia a la tracción de un papel depende de la resistencia de las fibras, pero principalmente del grado de enlace entre fibras (EK et al., 2009a). Por lo tanto, se utiliza con frecuencia en pruebas de pastas como una característica general de la capacidad de enlace entre fibras (LEVLIN & SÖDERHJELM, 1999). La composición del papel o sea la calidad de las fibras es, junto con el refino, los dos factores más influyentes sobre la resistencia a la tracción (NAVARRO SAGRISTÁ, 1966; SMOOK, 1990; EK et al., 2009a). El factor más importante que determina la resistencia a la tracción de un papel es el número de enlaces interfibrilares establecidos entre moléculas vecinas, que pueden pertenecer a la misma o distintas fibras (EK et al., 2009a). Es decir, al aumentar el refino se favorece la creación de nuevos enlaces y, por tanto, aumenta la resistencia a la tracción del papel. Si el refino es excesivo se produce un ligero descenso en la resistencia a la tracción, debido a la destrucción de la estructura de las fibras (SMOOK, 1990; SIERRA GRANADOS et al., 1998).

Si el extremo de una tira de papel lo sometemos a un esfuerzo de tracción, el papel sufre un alargamiento que irá aumentando con la fuerza, llegará un momento en el que el papel romperá, determinando entonces el alargamiento de rotura y la carga de rotura a la tracción. La longitud de rotura representa la longitud en metros que debe tener una tira de papel de cualquier ancho que fija por un extremo se rompa por su propio peso, o sea, la longitud cuyo peso sea igual a la carga de rotura (NAVARRO SAGRISTÁ, 1966; HOLIK, 2006). El alargamiento que sufre el papel por efecto de una tracción aumenta con el esfuerzo, con el gramaje, por su contenido en humedad, con el satinado, y disminuye con la longitud de las fibras (NAVARRO SAGRISTÁ, 1966). Las propiedades mecánicas en tracción en el plano son importantes en papeles destinados a impresión u otros usos en forma de bobina, así como en papeles y cartones para embalaje y fabricación de sacos (NISKANEN, 1998; HOLIK, 2006).

La resistencia al estallido sigue una tónica muy similar a la resistencia a la tracción, existiendo una buena correlación lineal entre ambas en la mayor parte de los papeles (SIERRA GRANADOS et al., 1998). Se define la resistencia al estallido o reventamiento como la presión límite que, aplicada perpendicularmente a su superficie, soporta una probeta de papel (AENOR, 2014). Representa la media de la solidez y elasticidad del papel en todas direcciones. Desde el punto de vista práctico tiene gran interés, pues además de no ser necesario el cortar tiras de papel, existen aparatos muy manejables para su determinación, y su medición es muy conveniente en todos aquellos papeles sometidos a choques o presiones interiores como embalajes, sacos, cartón ondulado, etc. (NAVARRO SAGRISTÁ, 1966; HOLIK, 2006).



Por todo lo mencionado anteriormente, unas de las propiedades más importantes dentro de control de producción en fábrica de la hoja de papel es el alargamiento, la resistencia a tracción y la resistencia al estallido ya que son indicadores de la cohesión de la hoja (NISKANEN, 1998). Sin embargo, los ensayos para determinar estas propiedades, dependientes de los parámetros de fabricación, carecen de la inmediatez necesaria para su aplicación en tiempo real en fábrica. Por esta razón, es importante el desarrollo de modelos matemáticos que relacionen los resultados de los ensayos antes mencionados con propiedades del papel más rápidas y fáciles de medir o parámetros de su producción, permitiendo realizar un control más rápido de la producción o llegando incluso a optimizar ésta.

Diversos estudios presentes en la literatura científica han explorado la aplicación de enfoques basados en redes neuronales artificiales (RNA) en el ámbito de la fabricación de papel. En general, estos trabajos se han focalizado en el desarrollo y uso de modelos neuronales para predecir propiedades específicas del papel, tales como resistencia, opacidad, porosidad y otros parámetros que son críticos para garantizar la calidad del producto final (SCHARCANSKI & DODSON, 1996; OLEJNIK & CIESIELSKI, 2004; NIEMINEN et al., 2011; CIESIELSKI & OLEJNIK, 2014; ADAMOPOULOS et al., 2016; OLEJNIK & CIESIELSKI, 2017). Por otra parte, algunos estudios han dirigido su atención al control del proceso de pasteado, abordando aspectos como la optimización de las condiciones operativas, el consumo de energía y la reducción de residuos generados durante el refinado de la celulosa (ELO et al., 1993; DAYAL et al., 1994; ZHU et al., 1997; ZHANG & AI, 2012).

Sin embargo, no se tiene constancia de que se haya realizado ninguna investigación específica que utilice inteligencia artificial (IA) para predecir los resultados de los ensayos de resistencia al estallido, la resistencia a tracción y su alargamiento de papel ya fabricado a partir de parámetros de fabricación o de propiedades fáciles de medir. La ausencia de estudios en este campo representa una oportunidad importante para la investigación futura, dado el potencial que tiene la IA para proporcionar predicciones precisas y en tiempo real, lo cual podría revolucionar los procesos de producción y control de calidad en la industria papelera.

2. Objetivos

El objetivo de este estudio ha sido obtener un modelo predictivo de la resistencia al estallido, la resistencia a tracción y su alargamiento de formetas de papel formadas en laboratorio y acondicionadas con la suficiente fiabilidad para su utilización en el control de calidad diario. Para ello, se ha desarrollado una red neuronal artificial a partir de los parámetros de fabricación.

3. Metodología

En este estudio, se han utilizado 288 formetas de papel en las cuales se ha medido la resistencia al estallido de acuerdo con la norma UNE-EN ISO 2758



(AENOR, 2014), la resistencia a tracción y el alargamiento de acuerdo con la norma UNE-EN ISO 1924-2 (AENOR, 2009) (Figura 1), el gramaje de acuerdo a la norma UNE-EN ISO 536 (AENOR, 2021) y el espesor de acuerdo a la norma UNE-EN ISO 534 (AENOR, 2012). La resistencia al estallido, resistencia a tracción y el alargamiento se han relacionado con los parámetros de producción del tipo de fibra (larga, corta y reciclada), gramaje, espesor y tiempo de refino. Este último de acuerdo con la norma UNE-EN ISO 5264-2 (AENOR, 2011).



Figura 1. Ensayo de resistencia a la rotura y alargamiento.

Todas las probetas se han obtenido de acuerdo con la norma UNE-EN 5269-1 (AENOR, 2005) y han sido acondicionadas según la atmósfera normalizada para ensayar pasta de papel, papel y cartón, la cual debe ser de 23 ± 1 °C y 50 ± 2 % de humedad relativa (HR) como especifica la norma UNE-EN ISO 187 (AENOR, 2023).

Los ensayos se realizaron según los protocolos de calidad establecidos en la norma UNE-EN ISO/IEC 17025 “Evaluación de la conformidad. Requisitos generales para la competencia de los laboratorios de ensayo y calibración” (AENOR, 2017). En la siguiente tabla (Tabla 1) se relacionan todos los equipos de ensayo.

Tabla 1. Equipos utilizados.



Equipamiento	Rango	División de escala
Cámara de acondicionamiento	(15-30)°C (30-85)%HR	0,1°C 0,1%HR
Balanza COMECTA ESJ 200	0-200g	0,0001g
Estufa Memmert UFB 400	0-220°C	1°C
Micrómetro de precisión centesimal Enrico Toniolo Modelo MBE	0-2 mm	0,01 mm
Máquina de ensayos universal (UTM), Testometric Micro 350	0-500 N 0-500 mm	0,001 N 0,001 mm
Formador manual de hojas Lhomargy modelo FO.02	159-215 mm de diámetro	1 mm
Prensa Lhomargy Modelo PR. 03	0-5 bar	0,1 bar
Desintegrador Lhomargy Modelo D1-01	0-99.999 rpm	1 rpm
Equipo para Ensayos de estallido Mullen IDMtest Mod. EM50	0-5.000 kPa	0,1 kPa

Para la modelización se ha utilizado un perceptrón multicapa. Las redes neuronales artificiales, como el perceptrón multicapa (HORNIK et al., 1989), (Figura 2), son herramientas robustas para modelizar relaciones entre variables con alta fiabilidad, aunque sin proporcionar un entendimiento directo de dichas relaciones (DE VEAUX et al., 1988). Su diseño es complejo, ya que no existe una regla fija para determinar su estructura interna, aunque se dispone de recomendaciones basadas en el número de datos (SHA, 2007; VANSTONE & FINNIE, 2009).

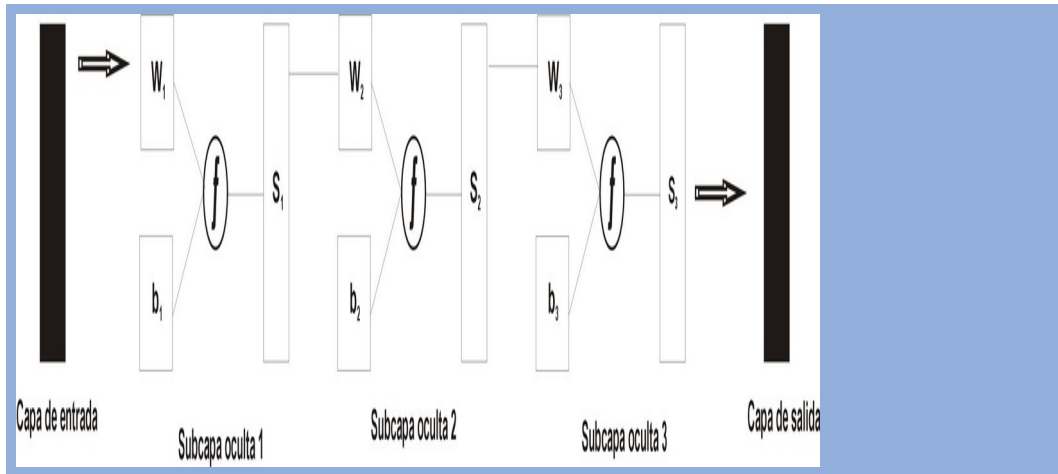


Figura 2. Esquema de una red neuronal artificial.

Un desafío clave es evitar el sobreentrenamiento, para lo cual los datos iniciales se dividen aleatoriamente en tres subconjuntos: entrenamiento, validación y comprobación. Los dos primeros se usan para entrenar la red y prevenir el sobreentrenamiento, mientras que el tercero evalúa su fiabilidad (BISHOP, 1995).

La tangente hiperbólica sigmoidea se utilizó como función de transferencia, dado que optimiza el rendimiento respecto a la tangente hiperbólica estándar (DEMUTH et al., 2002).

$$f(x) = \frac{2}{1 + e^{(-2x)}} - 1$$

$f(x)$ - Valor de salida de la neurona.
 x - Valor de entrada de la neurona.

Además, se normalizaron los valores de las variables independientes y dependientes para mejorar la efectividad de la función de transferencia (DEMUTH et al., 2002).

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

X' : Valor después de normalización del vector X .
 X_{min} y X_{max} : Valores máximo y mínimo del vector X .



El algoritmo de retropropagación resiliente fue empleado para el entrenamiento, ya que ofrece mejores resultados en redes con funciones de transferencia sigmoideas (DEMUTH et al., 2002).

Como variables de entrada a la red se han utilizado el tipo de fibra, tiempo de refino, gramaje y espesor (Tabla 2). Como variables de salida los resultados de los ensayos de tracción (carga de rotura y alargamiento) y estallido (Tabla 3). Para cada variable de salida se ha diseñado un perceptrón multicapa específico.

Tabla 2. Variables de entrada

Variable	Media	Desv. Típica	Mínimo	Máximo
Espesor (μm)	114	26	70	210
Gramaje (gr/m^2)	63,8	14,4	46,8	124,0
Tiempo refino (min)	12,5	11,5	0,0	30,0
Tipo de fibra:	Corta, larga, reciclada			

Tabla 3. Variables de salida

Variable	Media	Desv. Típica	Mínimo	Máximo
Carga de rotura (kg)	3,8	1,9	0,5	9,7
Alargamiento (%)	1,9	0,7	0,2	3,9
Resistencia al estallido (kg/cm^2)	1,9	1,0	0,3	4,6

4. Resultados

Los resultados obtenidos para cada una de las propiedades modelizadas se reflejan en la siguiente tabla (Tabla 4).

Tabla 4. Resultado de obtenidos para cada una de las propiedades

Propiedad	Estructura red neuronal	Fase	R2	R	p-valor
Carga de rotura (kg)	[3 3 3]	Entrenamiento	0,93	0,96	0,92
		Validación	0,93	0,96	
		Comprobación	0,94	0,97	
Alargamiento (%)	[5 5 2]	Entrenamiento	0,94	0,97	0,77
		Validación	0,88	0,94	
		Comprobación	0,91	0,96	
Resistencia al estallido (kg/cm ²)	[6 5 5]	Entrenamiento	0,97	0,98	0,93
		Validación	0,96	0,98	
		Comprobación	0,97	0,98	

Los valores obtenidos de R2 en el conjunto de comprobación indican que los modelos desarrollados explican como mínimo un 88% de la variabilidad de las muestras.

Todos los valores del p-valor obtenidos para los conjuntos de comprobación son superiores a 0,05 por lo que se puede concluir que no existen diferencias significativas entre los valores reales y los simulados mediante la red neuronal artificial con un nivel de confianza del 95%.

A partir de estos modelos se han obtenido gráficos 3D que permiten evaluar la influencia de las variables de entrada en el resultado final y, por tanto, optimizarlo (Figuras 3, 4 y 5).

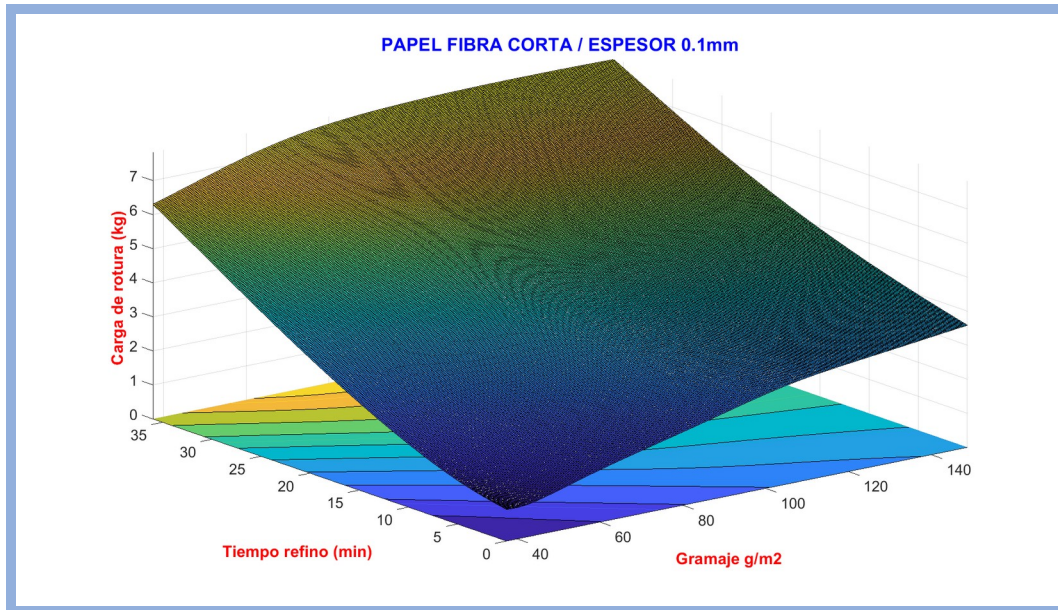


Figura 3. Modelización de la resistencia a rotura de un papel de fibra corta y 100µm de espesor en función del gramaje y el tiempo de refino.

En la figura 3 puede apreciarse cómo la resistencia a la rotura es directamente proporcional al gramaje y al tiempo de refino más pronunciado en el caso del tiempo de refino.

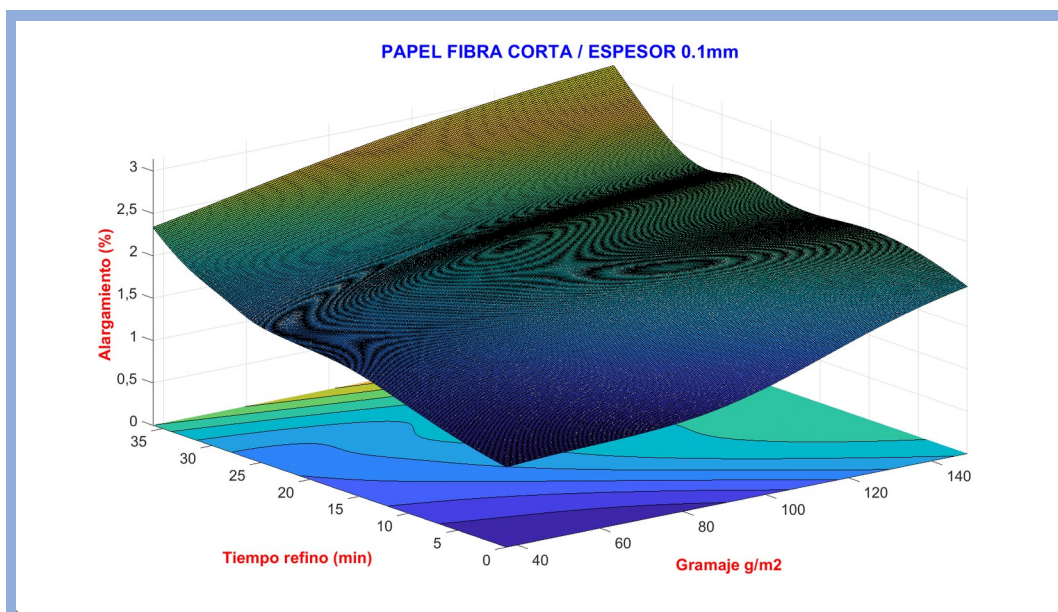


Figura 4. Modelización del alargamiento de un papel de fibra corta y 100µm de espesor en función del gramaje y el tiempo de refino.

En la figura 4 puede apreciarse cómo la resistencia a la rotura es directamente proporcional al gramaje y al tiempo de refino ligeramente más pronunciado en el caso del tiempo de refino. Se observa una pequeña distorsión en la evolución lineal de la propiedad para valores alrededor de 20 minutos de refino achacable probablemente a pequeñas desviaciones en los cálculos numéricos de la modelización y que no inciden en la evolución observada del alargamiento respecto al tiempo y gramaje.

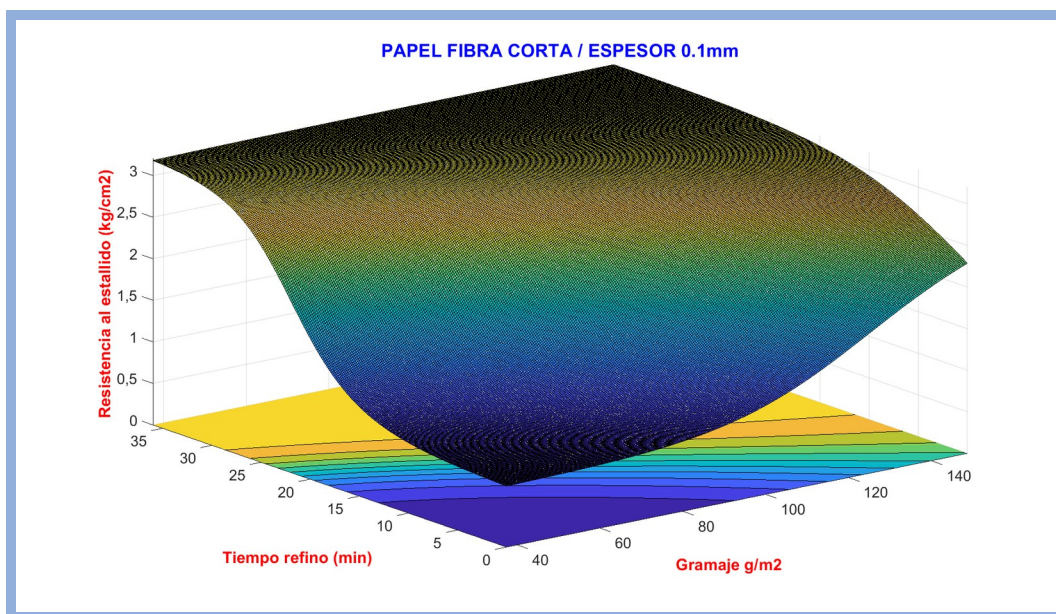


Figura 5. Modelización de la resistencia al estallido de un papel de fibra corta y $100\mu\text{m}$ de espesor en función del gramaje y el tiempo de refino.

En la figura 5 puede apreciarse cómo la resistencia al estallido es directamente proporcional al gramaje y al tiempo de refino más pronunciado en el caso del tiempo de refino.

5. Discusión

Todos los valores de los coeficientes de determinación obtenidos son iguales o superiores a 0,88, lo cual es coherente a los resultados obtenidos por estos autores en el desarrollo de redes neuronales en sus investigaciones de tableros derivados de la madera. GARCÍA FERNÁNDEZ et al. (2008) y ESTEBAN et al. (2009) reportaron coeficientes de determinación de 0,75 y 0,85, respectivamente, al modelar las



propiedades mecánicas de tableros de partículas utilizando propiedades físicas. Por su parte, ESTEBAN et al. (2010) lograron coeficientes de determinación de 0,92 y 0,94 al modelar las propiedades de tableros de partículas resistentes a la humedad tras procesos de envejecimiento cíclico.

En otro estudio, GARCÍA FERNÁNDEZ et al. (2012) informaron coeficientes de determinación de 0,66 a 0,73 para el conjunto de pruebas, al modelar la resistencia a la flexión y el módulo de elasticidad de contrachapados estructurales utilizando otras propiedades físico-mecánicas. Además, en una investigación sobre la influencia de las propiedades físicas en la cohesión interna de tableros de partículas tipo P2, DE PALACIOS et al. (2018) obtuvieron un coeficiente de determinación de 0,83.

Igualmente, los coeficientes de correlación obtenidos superiores a 0,95, también concuerdan con los de otros autores que han utilizado las redes neuronales en el ámbito de la tecnología de la celulosa y el papel.

Así, SANTOS et al. (2022) obtuvieron coeficientes de correlación de alrededor de 0,99 en la predicción de la relación de aspecto de productos de micro/nanofibras, demostrando la alta precisión de su modelo. Este se fundamentó en parámetros clave, como el contenido de celulosa, la energía aplicada durante el proceso, la longitud de las fibras y el diámetro de las pulpas pretratadas. Estas variables, además de ser fáciles de medir, reflejan tanto las condiciones operativas como las características iniciales de las fibras, lo que permite una evaluación precisa y práctica del comportamiento de los materiales en el contexto estudiado.

También, CIESIELSKI & OLEJNIK (2014) obtuvieron coeficientes de correlación alrededor de 0,90 en su estudio de estimación de las propiedades del papel a partir de las propiedades químicas de la pulpa mediante redes neuronales artificiales.

Estos mismos autores obtuvieron coeficientes de correlación entre 0,97 y 0,99 en su modelización de las propiedades del papel a partir de los parámetros del refino o de las propiedades de la pulpa de papel. Llegaron a la conclusión de que el mejor modelo para estimar las propiedades del papel era el basado en las propiedades de la pulpa llegando a un coeficiente de correlación de 0,99, aunque en el caso de la modelización con los parámetros de refino obtuvieron el no desdeñable valor de 0,97.

ALMONTI et al. (2021) lograron coeficientes de determinación próximos a 0,99 en su estudio sobre la caracterización de pulpa y papel mediante redes neuronales artificiales. Su investigación se centró en identificar y modelar las principales propiedades electroquímicas y físicas de la pulpa y el papel, con el objetivo de optimizar procesos y reducir la generación de residuos sólidos en los efluentes.

En un estudio previo, ALMONTI et al. (2019) desarrollaron una red neuronal artificial que alcanzó un coeficiente de determinación de 0,98 en la predicción de



la longitud de las fibras y el control del proceso de refinado de celulosa. La red fue entrenada con datos experimentales para predecir la longitud de las fibras en función de las variables operativas del refinado. Este parámetro es clave para garantizar propiedades específicas del papel, y su predicción permite optimizar tanto la cantidad de aditivos como los parámetros del proceso, logrando así las características deseadas en el producto final.

En cuanto a las modelizaciones realizadas de los ensayos de tracción (carga de rotura y alargamiento) y resistencia al estallido, son coherentes con lo indicado por SIERRA GRANADOS et al. (1998) y LEVLIN & SÖDERHJELM (1999) los cuales explican que estas propiedades son proporcionales al gramaje y el refino, aumentando según aumentan cada uno de ellos.

6. Conclusiones

Se han diseñado tres redes neuronales artificiales para la modelización de los ensayos de tracción (carga de rotura y alargamiento) y resistencia al estallido con coeficientes de correlación superiores a 0,95.

Los coeficientes de determinación de las redes desarrolladas permiten explicar al menos el 88% de la variabilidad de las muestras.

Las redes han permitido estudiar la evolución de dichas propiedades en función del tipo de fibra, tiempo de refino, gramaje y espesor observándose una relación directa entre la carga de rotura, el alargamiento y la resistencia al estallido con el tiempo de refino y el gramaje.

7. Bibliografía

ADAMOPOULOS, S.; KARAGEORGOS, A.; RAPTI, E.; BIRBILIS, D.; 2016. Predicting the properties of corrugated base papers using multiple linear regression and artificial neural networks. *Drewno* 198 61 – 72.

AENOR; 2005. Norma UNE-EN ISO 5269-1. Preparación de hojas de laboratorio para ensayos físicos. Parte 1: Método del formador de hojas convencional (ISO 5269-1: 2005). Pastas. Madrid, España.

AENOR; 2009. Norma UNE-EN ISO 1924-2. Determinación de las propiedades de tracción. Parte 2: Método con gradiente de alargamiento constante (20 mm/min) (ISO 1924-2: 2008). Papel y cartón. Madrid, España.

AENOR; 2011. Norma UNE-EN ISO 5264-2. Refino de laboratorio. Parte 2: Método del molino PFI (ISO 5264-2: 2011). Pastas. Madrid, España.



AENOR; 2012. Norma UNE-EN ISO 534. Determinación del espesor, densidad y volumen específico (ISO 534: 2011). Papel y cartón. Madrid, España.

AENOR; 2014. Norma UNE-EN ISO 2758. Determinación de la resistencia al estallido. Papel. Madrid, España.

AENOR; 2017. Norma UNE-EN ISO/IEC 17025. Requisitos generales para la competencia de los laboratorios de ensayo y calibración. Madrid, España.

AENOR; 2021. Norma UNE-EN ISO 536. Determinación del gramaje (ISO 536:2019). Papel y cartón. Madrid, España.

AENOR; 2023. Norma UNE-EN ISO 187. Atmósfera normal de acondicionamiento y ensayo y procedimiento para controlar la atmósfera y el acondicionamiento de muestras. (ISO 187:2022). Papel, cartón y pastas. Madrid, España.

ALMONTI, D.; BAIOTTO, G.; TAGLIAFERRI, V.; UCCIARDELLO, N.; 2019. Artificial Neural Network in Fibres Length Prediction for High Precision Control of Cellulose Refining. *Materials* 12 3730.

ALMONTI, D.; BAIOTTO, G.; UCCIARDELLO, N.; 2021. Pulp and paper characterization by means of artificial neural networks for effluent solid waste minimization—A case study. *J Process Control* 105 283 – 291.

ASPAPPEL; 2021. Memoria de sostenibilidad. Año 2021. 140 pp. Madrid.

ASPAPPEL; 2024. Presentación corporativa. Asociación, sector y sostenibilidad. Datos 2023.

BISHOP C.M.; 1995. Neural networks for pattern recognition. Oxford University Press. 498pp. Oxford.

CIESIELSKI, K; OLEJNIK, K.; 2014. Application of Neural Networks for Estimation of Paper Properties Based on Refined Pulp Properties. *FIBRES & TEXTILES in Eastern Europe* 22 126 – 132.

DAYAL, B.S.; MACGREGOR, J.; TAYLOR, P.A.; 1994. Application of Feedforward Neural networks and Partial Least Squares Regression to Modeling Kappa Number in a Continuous Kamyr Digester. *Pulp Pap Can* 95 26 – 32.

DE PALACIOS, P.; FERNÁNDEZ, F.G.; GARCÍA-IRUELA, A.; GONZÁLEZ-RODRIGO, B.; ESTEBAN, L.G.; 2018. Study of the influence of physical properties on internal bond



of particleboard type P2 using artificial neural networks. *Comput Electron Agric* 155 142 – 149.

DE VEAUX; R.D.; SCHUMI; J.; SCHWEISBERG; J.; UNGAR L.H.; 1988. Prediction intervals for neural networks via nonlinear regression. *Technometrics* 40(4) 273 – 282.

DEMUTH H.; BEALE M.; HAGAN M.; 2002. Neural Network Toolbox User's Guide, Version 4. The MathWorks Inc. 846pp. Natwick.

EK, M.; GELLERSTEDT, G.; HENRIKSSON, G.; 2009a. Pulp and Paper Chemistry and Technology. Volume 2: Pulping Chemistry and Technology. Walter de Gruyter GmbH & Co. KG. 471 pp. Berlín.

EK, M.; GELLERSTEDT, G.; HENRIKSSON, G.; 2009b. Pulp and Paper Chemistry and Technology. Volume 4: Paper Products Physics and Technology. Walter de Gruyter GmbH & Co. KG. 342 pp. Berlín.

ELO, P.; SAARINEN, J.; KASKI, K.; PAKARINEN, P.; KIISKINEN, H.; KAIJALUOTO, S.; EDELMANN, K.; 1993. Analysis of quality properties in paper drying with neural networks. Proceedings of 1993 International Joint Conference on Neural Networks.

ESTEBAN, L.G.; GARCÍA FERNÁNDEZ, F.; DE PALACIOS, P.; CONDE, M.; 2009. Artificial neural networks in variable process control: application in particleboard manufacture. *Inv Agrar Sist Recursos Fores* 18 92 – 100.

ESTEBAN, L.G.; GARCÍA FERNÁNDEZ, F.; DE PALACIOS, P.; GONZÁLEZ RODRIGO, B.; 2010. Use of artificial neural networks as a predictive method to determine moisture resistance of particle and fiber boards under cyclic testing conditions (UNE-EN 321). *Wood Fiber Sci* 42 1 – 11.

FAO; 2022. Anuario FAO de productos forestales 2020, FAO STATISTICS. 464pp. Roma.

GARCÍA FERNÁNDEZ, F.; DE PALACIOS, P.; ESTEBAN, L.G.; GARCÍA-IRUELA, A.; GONZALEZ RODRIGO, B.; MENASALVAS, E.; 2012. Prediction of MOR and MOE of structural plywood board using an artificial neural network and comparison with a multivariate regression model. *Compos Pt B-Eng* 43 3528 – 3533.

GARCÍA FERNÁNDEZ, F.; ESTEBAN, L.G.; DE PALACIOS, P.; NAVARRO, N.; CONDE, M.; 2008. Prediction of standard particleboard mechanical properties utilizing an artificial neural network and subsequent comparison with a multivariate regression model. *Inv Agrar Sist Recursos Fores* 17 178 – 187.



GARCÍA IRUELA, A.; BOBADILLA MALDONADO, I.; LÓPEZ ÁLVAREZ, J.V.; 2023. Prácticas de celulosa y papel. Fundación Conde del Valle de Salazar. 90 pp. Madrid.

HOLIK, H.; 2006. Handbook of paper and board. WILEY-VCH Verlag GmbH & Co. 505 pp. Weinheim.

HORNIK K.; STINCHCOMBE M.; WHITE H.; 1989- Multilayer feedforward networks are universal approximators. *Neural Networks* 2 359 – 366.

LEVLIN, J.E.; SÖDERHJELM, L.; 1999. Pulp and Paper Testing. Fapet Oy. 287 pp. Helsinki.

LÓPEZ ÁLVAREZ, J.V.; AGUILAR LARRUCEA, M.; TORREJÓN GÓMEZ, R.; ARRAIZA BERMÚDEZ-CAÑETE, P.; ARRANZ SUALDEA, J.C.; 2011. Manual de interpretación de las características de pastas de celulosa y del papel. Fundación Conde del Valle de Salazar. 109 pp. Madrid.

NAVARRO SAGRISTÁ, J.; 1966. Propiedades, ensayos y análisis del papel. Sucesores de Limousin Hermanos. 117 pp. Alcoy.

NIEMINEN, P.; KÄRKKÄINEN, T.; LUOSTARINEN, K.; MUHONEN, J.; 2011. Neural Prediction of Product Quality Based on Pilot Paper Machine Process Measurements. ICANNGA'11-10th International Conference on Adaptive and Natural Computing Algorithms. Berlin/Heidelberg, Alemania, 240 – 249.

NISKANEN, K.; 1998. Paper physics. Fapet Oy. 324 pp. Helsinki.

OLEJNIK, K.; CIESIELSKI, K.; 2004. Neural network model of pulp refining process. *Chem Process Eng* 25 1411 – 1416.

OLEJNIK, K.; CIESIELSKI, K.; 2017. Evaluation of the different strategies for the pulp refining process effects estimation using artificial neural networks. *Przegląd Papierniczy* 73 343 – 348.

ORTUÑO, S.; GONZÁLEZ GONZÁLEZ, V.; 2021. La estructura económica del sector forestal en España 2000-2020. Ministerio para la Transición y el Reto Demográfico. 319 pp. Madrid.

SANTOS, A.F.; AGUADO, R.; CORAZZA, M.L.; TARRÉS, Q.; SANCHEZ-SALVADOR, J.L.; BLANCO, A.; NEGRO, C.; DELGADO-AGUILAR, M.; 2022. Artificial neural network for aspect ratio prediction of lignocellulosic micro/nanofibers. *Cellulose* 29 5609 –



5622.

SCHARCANSKI, J.; DODSON, C.T.J.; 1996. Neural network model for paper forming process. Proceedings of the Pulp and Paper Industry Technical Conference, Birmingham, Estados Unidos de América, 236–255.

SHA W.; 2007. Comment on the issues of statistical modelling with particular reference to the use of artificial neural networks. *Applied Catalysis A-General* 324 87 – 89.

SIERRA GRANADOS, L.; DELGADO FALCÓN, D.A.; LÓPEZ ÁLVAREZ, J.V.; 1998. Fundación Conde del Valle de Salazar. Apuntes de la unidad de celulosa y papel. 180 pp. Madrid.

SMOOK, G.A.; 1990, Manual para técnicos de pulpa y papel. Tappi press. 396 pp. Atlanta.

VANSTONE B.; FINNIE G.; 2009. An empirical methodology for developing stockmarket Trading Systems using artificial neural Networks. *Expert systems with Applications* 36 6668 – 6680.

ZHANG, Y.; AI, J.; 2012. Zeta Potential Modeling of Papermaking Wastewater on Neural Network. Second International Conference on Instrumentation, Measurement, Computer, Communication and Control, Harbin, China, 63 – 66.

ZHU, J.; XIA, Q.; RAO, M.; ZURCHER, J.; 1997. A Neural Network for Modeling Pulp Process. *Pulp Pap Can* 98 35 – 38.