



UNIVERSIDAD
POLITECNICA
DE VALENCIA

**MODELADO DEL PROCESO DE EXTRUSIÓN PARA UNA
BASE ALMIDÓN/FIBRA: SIMULACIÓN DE LA INFLUENCIA DE
LAS CONDICIONES DE ENTRADA EN LAS VARIABLES
RESPUESTA OPERACIONALES Y EN LAS PROPIEDADES
FÍSICO-QUÍMICAS DEL PRODUCTO.**

MÁSTER EN CIENCIA E INGENIERÍA DE LOS ALIMENTOS

AUTOR:

JORGE REVECO PALACIOS

DIRECTOR ACADÉMICO:

JOSÉ BON CORBIN

CENTRO:

Departamento de Tecnología de Alimentos.
Grupo de Análisis y Simulación de Procesos Agroalimentarios (ASPA)

DIRECTOR TÉCNICO:

VICTORIA CAPILLA

CENTRO:

Asociación de Investigación de la industria agroalimentaria (AINIA).

RESUMEN

La cocción por extrusión está siendo cada vez más utilizada en la industria alimentaria, principalmente gracias a su versatilidad en la creación de nuevos productos y a su eficiencia, tanto productiva como energética. Este hecho ha generado la necesidad de un mayor conocimiento de los fenómenos físicos, químicos y microbiológicos de la materia prima involucrados en esta técnica, que afectarán a las características de calidad finales del producto. En organizaciones dedicadas a la investigación y desarrollo de productos extrusionados, el entendimiento de este proceso es vital para facilitar la entrega de nuevas y óptimas soluciones aplicables en las empresas del sector. Por ello, el trabajo actual ha pretendido modelar la influencia de las condiciones de operación de un proceso de extrusión sobre las características de calidad del producto. Para ello se desarrollaron un conjunto de modelos matemáticos basados en redes neuronales artificiales, útiles para simular procesos alimenticios complejos, en donde existen gran cantidad de relaciones lineales y/o no lineales, y que requerirían un mínimo nivel de simplificaciones y aproximaciones para poder ser modelados mediante modelos teóricos.

El estudio se enfoca en la influencia de 3 variables manipulables de operación: el flujo másico de materia prima seca, la velocidad de husillos y la humedad en la mezcla inicial. Las variables de respuesta se separaron en 2 grupos: (i) variables medibles en línea, como la temperatura de boquilla, la presión de boquilla y el torque par del motor del equipo; (ii) variables correspondientes a algunas de las características finales de producto, como propiedades físico-químicas y sensoriales, imposibles de ser obtenidas *in situ*. Se desarrolló una red neuronal para modelar la influencia de las condiciones de operación sobre las variables de respuesta medibles, obteniendo ajustes óptimos. Para poder modelar con suficiente exactitud el efecto de las condiciones de operación sobre las características finales del producto, se desarrolló una red neuronal para cada característica. El conjunto de redes neuronales modeladas constituyen modelos ajustados con suficiente exactitud para ser aplicados en futuros trabajos de simulación y optimización.

Palabras claves: cocción, extrusión, modelación, red neuronal artificial, almidón-fibra.

ABSTRACT

Extrusion cooking is being increasingly used in the food industry, mainly due to its versatility in the creation of new products and its efficiency, both productive and energetic. This has created the need for a better understanding of the physical, chemical and microbiological raw material involved in this technique, which affect the quality characteristics of the final product. In organizations dedicated to the research and development of extruded products, understanding of this process is vital to facilitate the delivery of new and optimal solutions applicable in companies. Therefore, the present work has attempted to model the influence of the operating conditions of an extrusion process on the quality characteristics of the product. This developed a set of mathematical models based on artificial neural networks, useful for simulating complex food processes, where there are lots of relationships linear and / or nonlinear, and require a minimum level of simplifications and approximations to be modeled by theoretical models.

The study focused on the influence of 3 manipulable operating variables: mass flow of dry raw material, the spindle speed and the moisture in the starting mixture. The response variables were separated into 2 groups: (i) measurable variables online such as the temperature of nozzle, the nozzle pressure and the motor torque gear pair, (ii) some variables relating to the characteristics of the end product as physicochemical properties and sensory impossible to be obtained *in situ*. We developed a neural network to model the influence of operating conditions on the response variables measured, obtaining optimal settings. To be able to model with sufficient accuracy the effect of operating conditions on the final characteristics of the product, developed a neural network for each feature. The set of neural networks are adjusted models modeled with sufficient accuracy to be applied in future work simulation and optimization.

Keywords: cooking, extrusion, modeling, artificial neural network, starch-fiber.

1. INTRODUCCIÓN

Las aplicaciones de cocción por extrusión (*cooking extrusion*) a alta temperatura y corto tiempo en alimentos (Kumar *et al.*, 2008), con base en carbohidratos, proteínas y fibra, están siendo cada vez más aplicadas por la industria alimentaria en la elaboración de una gran variedad de productos e insumos, como snacks expandidos, alimentos listos para comer, almidones modificados, pellets para consumo de animales en explotaciones agropecuarias o mascotas (Wang *et al.*, 2006; Ficarella *et al.*, 2006)

Los procesos de extrusión nacen en la industria de polímeros sintéticos, generando una gran cantidad de investigaciones e información, provocando con el paso de los años que se fueran descubriendo más posibilidades de aplicación de esta tecnología en los procesos de fabricación, siendo inevitable finalmente la transferencia tecnológica hacia la producción de alimentos. Dentro de las ventajas que se pueden destacar, y que han llevado al proceso de extrusión a crecer de forma importante dentro del área alimentaria estos últimos 20 años, se puede mencionar su gran versatilidad para la creación de nuevos productos, con un amplio rango de materias primas posibles de utilizar en el mismo equipamiento base, además de poseer una eficiencia energética alta y la casi nula producción de efluentes contaminantes (Neelam *et al.*, 2006).

Sin embargo, a diferencia de la fabricación de polímeros sintéticos, los fenómenos presentes dentro de un extrusor de alimentos, que actúa paralelamente como un intercambiador de calor y un biorreactor (Moya de la Torre, 2005) son totalmente diferentes. Definir los cambios que ocurren en las materias primas para obtener productos finales de calidad es un trabajo que presenta muchas dificultades. Existen numerosas variables involucradas, así como fenómenos complejos que deben considerarse en forma conjunta o separada, generando en ocasiones relaciones no lineales de compleja resolución matemática, siendo necesario recurrir a aproximaciones para simplificar su manejo, limitando los resultados obtenidos por los modelos matemáticos aplicados (Mercier *et al.*, 1989). El aumento en la digestibilidad por la gelatinización del almidón y desnaturalización de proteínas, la prolongación de la vida útil por destrucción microbiana, inactivación enzimática y deshidratación por altas presiones y expansión, junto a las modificaciones en las propiedades físicas, como geometría, viscosidad, densidad, textura, dureza entre otras, son ejemplos de estos cambios complejos.

En el modelado de procesos de extrusión, en estas últimas décadas se han propuesto variados modelos de extrusión (Cheng y Friis. 2010; Li, C. 2001; Wang, L. *et al.*, 2006), tanto para extrusión simple como de doble husillo, la mayoría basadas principalmente en fenómenos físico – mecánicos y resolución matemática convencional. Existe otro tipo de modelación de sistemas multivariables que ha ganado atractivo y adherentes durante este último tiempo: las redes neuronales artificiales (ANNs). Basando su modelo de resolución de sistemas lineales y no lineales, en un método de trabajo a través de elementos conectados mediante interconexiones simples, trabajando en ensayos prueba y error, cambiando en forma iterativa el tipo y

tamaño de las interacciones entre las neuronas que componen la red, y comparando las variables ingresadas como respuesta, con los resultados procedentes de estas iteraciones, buscando alcanzar el nivel de precisión especificado por el desarrollador. La red neuronal (ANN) va adquiriendo con este tipo de proceso un entrenamiento y aprendizaje, almacenado en los pesos sinápticos, que posibilita su especificidad a las características de cada proceso en particular, con la posibilidad de incluir con el tiempo mayor cantidad de información sin la necesidad de reestructurar el modelo nuevamente, ventaja muy cómoda para tareas de investigación (Neelam *et al.*, 2006). En la industria alimentaria se han utilizado para modelar procesos de vinificación (Rattaray and Floros, 1999), en enzimología para simular el sistema de control para productos expandidos (Eerikainen *et al.*, 1994), etc. El desarrollo y aplicación de ANNs han permitido plantear modelos para tiempo de residencia, simulación del proceso en estado estacionario o transitorio, o para pronosticar la influencia de las variables manipulables sobre las características físico-químicas del producto, aspecto relevante que permite establecer un sistema de control fiable al proceso alimentario (Haley and Mulvaney, 1995).

Por lo tanto, conocer la influencia de las variables manipulables es fundamental para prever los posibles resultados que se obtendrán en la práctica. La Asociación de Investigación de la industria agroalimentaria (AINIA), consciente de ello, tiene como preocupación desarrollar un modelo que se adecue a su equipo de extrusión, evitando problemas de operación, aumentando su eficiencia y mejorando el trabajo para encontrar nuevas aplicaciones o avances al proceso de cocción por extrusión.

El objetivo de este trabajo se centra en el desarrollo de redes neuronales para simular el funcionamiento del extrusor con que cuenta AINIA, que permitan entender más a fondo el proceso, la influencia de las variables manipulables sobre las propiedades del producto, y optimizar el proceso de extrusión según los objetivos perseguidos.

2. MATERIALES Y MÉTODOS

2.1. Redes neuronales

Una ANN corresponde a una configuración estructural de capas distribuida en forma paralela, en la cual existen interconexiones entre los elementos que la constituyen, denominadas neuronas. El tipo más utilizado de configuración de ANNs son las de tipo alimentación hacia adelante, consistente en un conjunto de nodos de origen que constituyen la entrada a una capa, una o más capas ocultas y una capa de salida. En una red neuronal de alimentación hacia adelante, la señal de entrada se propaga a través de la red en una dirección hacia adelante, sobre capa por capa. Existe la posibilidad conectar las salidas con las entradas con una retroalimentación cuando el proceso lo requiere, pero en la configuración general la red solo tiene dirección de avance (Popescu *et al.*, 2000).

Para el entrenamiento de la red y finalmente su adecuación y aprendizaje del proceso, el sistema utiliza el llamado "error de propagación hacia atrás" que tiene dos pasos a través de las diferentes capas de la red neuronal. El primero se mueve hacia adelante y el segundo hacia atrás. En el paso hacia adelante, un conjunto de entradas son aplicadas a los nodos de entrada de la red, y su efecto se propaga a través la red, capa por capa, produciendo un conjunto de salidas, las cuales son tomadas como respuestas reales de la red.

Durante el proceso, los pesos sinápticos de la red son guardados y fijados. Las respuestas reales de la red se restan a las respuestas deseadas, introducidas gracias a datos experimentales, produciendo una señal de error que se propaga hacia atrás en la red, esto constituye el pase hacia atrás, en la que los pesos sinápticos son ajustados de acuerdo con la regla de corrección de errores introducida. Los pesos se ajustan con el fin de que la respuesta real de la red se acerque lo más posible a la respuesta deseada. Algoritmos para este tipo de configuración se pueden encontrar en la bibliografía (Guy 2001; Haykin 1994).

Para la modelación del proceso en estudio, se definieron dos grupos de variables de respuesta, lo que conllevaba el diseño de dos modelos diferentes. Un primer modelo simulará la operación del equipo, en donde participan variables, tanto de entrada como salida, medibles *insitu*: flujo másico (Q_m), humedad (W), velocidad del husillo (n), temperatura salida (T_b) o boquilla, presión salida (P_b) o boquilla, torque par motor (τ). El segundo modelo para simular el efecto de las variables manipuladas (Q_m , W , n) sobre las características del producto final que no pueden ser medibles en tiempo real: humedad (X_w), capacidad retención de agua (WA), densidad aparente (BD), grado de expansión (EI), energía mecánica específica (SME) y propiedades ópticas (L^* , C^* , h^*). Esta separación fue necesaria, ya que, si se quisiera realizar un modelo que involucre todas las variables de salida, se necesitaría una mayor cantidad de datos, con una estructura de red neuronal mucho más pesada y, por ende, más compleja.

Para el diseño de las ANNs necesarias, calculando el número de neuronas, pesos y bias, se consideró una multicapa alimentada hacia adelante con un algoritmo de entrenamiento de propagación hacia atrás. Para determinar la cantidad de capas ocultas y nodos no existe una regla fija, en general, una capa oculta es adecuada, y sólo en algunos casos, puede haber una ligera mejora con el uso de dos capas ocultas (Goñi *et al.*, 2008). Por lo tanto, tomando 1 capa oculta, el número de neuronas por capa fue necesario de determinar. Para ello se estableció como funciones de transferencia, la función sigmoideal para cada capa oculta y una función lineal para la capa de salida. Aplicando el paquete de herramientas denominada Neural Network Toolbox de Matlab R2011b (The Mathworks, 2011), se estructuró una red con alimentación hacia adelante y propagación hacia atrás. Los valores de los parámetros de cada red se definieron a través de un procedimiento de entrenamiento, con el objetivo de minimizar los errores cuadráticos medios (MSE) entre las salidas de la red y los valores experimentales, utilizando el algoritmo de Levenberg-Marquardt (Levenberg, 1944; Marquardt, 1963).

Para evitar el problema de exceso de ajuste durante el entrenamiento de redes neuronales, los vectores de entrada y de salida de cada ANN fueron divididos al azar, con un 70% utilizado para el entrenamiento, el 15% para la validación y el 15% para la prueba. Finalmente para seleccionar la red idónea (teniendo en cuenta todos los datos experimentales y calculados) se tomo en cuenta el valor del coeficiente de correlación entre datos experimentales y estimados, el valor MSE general, los coeficientes de correlación estimados en cada parte de la formación de la ANN (entrenamiento, validación y pruebas), y el número de neuronas (el número más bajo posible para obtener el menor número de pesos y bias).

2.2. Materia Prima

La matriz utilizada fue similar a la empleada en la producción de cereales para el desayuno y bases de snack, compuesta en su mayor parte por harina de cereal, responsable de los cambios principales que determinarían las características finales del producto. En la tabla 1 se detalla la composición.

TABLA 1. Composición de matriz.

Matriz de Formulación	
Materia Prima	%
Harina de Trigo	86,7%
Sal (NaCl)	1,5%
Azucar	8,5%
Levadura	0,30%
Fibra Vegetal	3,0%
Total BS	100%

BS: Base seca

El agua necesaria para completar la matriz fue agregada en forma continua, con una bomba de desplazamiento positivo, calibrada con anticipación a las pruebas.

2.3. Experiencias de extrusión

Las pruebas fueron realizadas en las dependencias de AINIA, donde se llevaron a cabo tareas de calibración, preparación y carga de materia prima, monitoreo, toma de muestras y datos operacionales. Se siguió un orden lógico de operación para las experiencias relacionadas con las capacidades y la mejor operatividad del equipo.

2.3.1 Equipo de extrusión

El equipo de extrusión corresponde a un sistema con doble husillo corrotativo con 5 zonas de monitoreo de temperatura con termopares, de las cuales 4 zonas tienen control manual, y una zona de alimentación con tornillo sin fin automático controlado por un variador de frecuencia, el cual fue calibrado con anticipación a las experiencias. Para regular el

calentamiento de la muestra en extrusión, el equipo dispone de un sistema de enfriamiento, con agua de red, y un sistema de calentamiento con resistencias eléctricas (4 zonas). En la salida existe una zona de expansión con la posibilidad de intercambiar boquillas de salida, utilizando en este caso una boquilla circular con diámetro 2 mm. En la tabla 2 se muestra un resumen de las características del equipo.

TABLA 2. Características de equipo.

Extrusor Doble Husillo Corrotativo		
Marca	Clextral	
Modelo	BC 21	
Diámetro husillo	25	mm
Largo carcasa	500	mm
L/D*	20	
Vel max husillo	680	RPM
Presión máxima	200	bar
Tª máxima	300	°C
Flujo producción	5 a 50	kg/h
Tipo de refrigeración	4 zonas, manual	

2.3.2 Diseño Experimental

Para la definición del conjunto de variables manipulables y de respuesta que se utilizarían para estructurar el modelo, fue necesario el estudio del equipo y qué posibilidades de control disponía a la hora de realizar las pruebas (sistema de control y monitoreo). Se estableció como variables manipulables (INPUT) Q_m , n y W , y como variables de respuesta (OUTPUT), T_b , P_b y τ .

Si bien la temperatura en cada zona es relevante para un estudio acabado del proceso, este parámetro no fue incluido debido a la imposibilidad de una monitoreo y control fiable; por tanto se establecieron valores constantes para todas las experiencias. Se planteó la importancia de conocer las características finales del producto relevantes para la aceptación final de este, incluyéndose estas en el estudio y el modelo. Debido a que no existe tecnología que permita la medición en línea de estas propiedades, en relación a los recursos y capacidades actuales, las siguientes fueron considerados: EI, BD, SME, X_w , WA y color. Tales propiedades se consideraron como las variables de salida para el modelo que relacionará las variables de entrada con las características del producto.

Como las características del producto, en su mayoría son obtenidas con determinaciones analíticas, y estas fueron realizadas en instalaciones de la Universidad Politécnica de Valencia (UPV), se planteó la necesidad de aumentar la estabilidad de las muestras y evitar posibles cambios indeseados; para ello se secaron las muestras luego de la extrusión a una temperatura de 40°C por 30 minutos, en un secadero de bandejas propiedad de AINIA.

Un diagrama explicativo de las variables involucradas y del proceso utilizado para el planteamiento, desarrollo y toma de datos para ajustar las ANNs, se muestra en la figura 1.

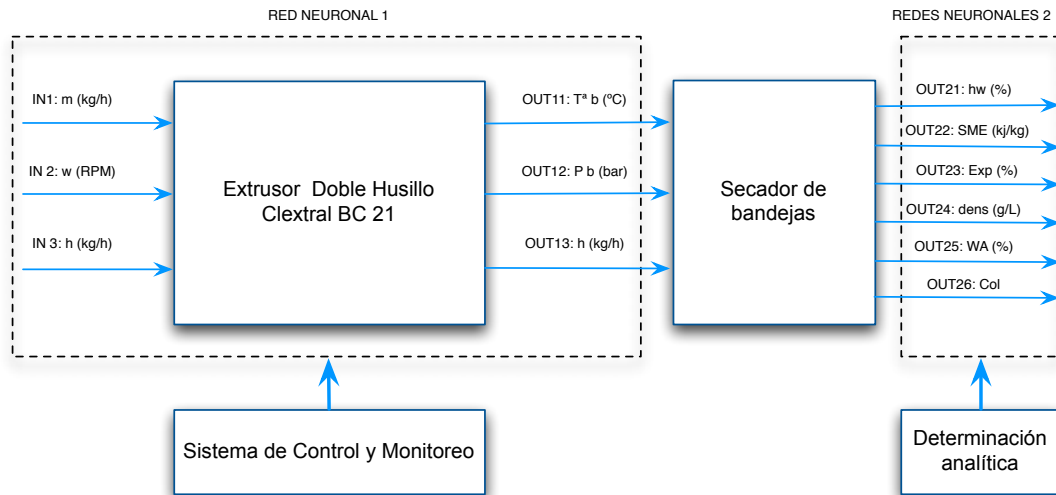


FIGURA 1. Diagrama de proceso con variables entradas y salidas

En el diseño de experiencias a realizar en la planta piloto se utilizó la herramienta **Model-calibration**, perteneciente al software matemático desarrollado para MATLAB, en la versión 7.13 (R2011b). En consideración a la cantidad de entradas y salidas se utilizó un modelo de tipo cúbico con 3 INPUTs y 2 interacciones, en un diseño de tipo V – optimal, el cual minimiza los errores en la varianza del conjunto de datos.

2.3.3 Determinaciones analíticas

Debido a las características de las muestras, como baja humedad, baja actividad enzimática, ausencia de microorganismos y una composición de grasa reducida, se almacenaron las mismas en un lugar fresco y seco, previamente a su análisis no más allá de 5 días desde que se tomaron las muestras. Las determinaciones analíticas fueron realizadas por triplicado en instalaciones de la UPV.

Determinación de contenido agua (X_w)

Para la determinación de la X_w, expresada como fracción másica de agua, se siguió una adaptación del método 934.06 (AOAC, 2000) para una muestra sin volátiles, rica en azúcares y baja en humedad.

$$X_w = \frac{m_{\text{agua}}}{m_{\text{total}}} = \frac{m_{\text{humeda}} - m_{\text{seca}} - m_{\text{crisol}}}{m_{\text{humeda}}} \quad (1) \quad (1)$$

Determinación de capacidad de retención de agua (WA)

WA fue determinada por diferencia de peso tras sumergir una muestra ($m_{inicial}$) ya pesada (0.2 g) en 30 mL durante 1 hora, posteriormente se seco cuidadosamente y se volvió a pesar (m_{final}).

$$WA(\%) = \frac{m_{final}}{m_{inicial}} \cdot 100 \quad (2)$$

Determinación de la densidad aparente (BD)

BD fue obtenida tomando muestras de extrusado de 2 cm de longitud, llenando un volumen conocido (100 mL) ($V_{contenido}$), y pesando posteriormente el contenido total ($m_{muestra}$).

$$BD = \frac{m_{muestra}}{V_{contenido}} (g / L) \quad (3)$$

Determinación del grado de expansión (EI)

Para la determinación de EI se siguió el procedimiento adoptado por Álvarez – Martínez et al. (1988).

$$EI = \frac{D_e^2}{D_d^2} \quad (4)$$

D_e corresponde al diámetro del extrusado y D_d al diámetro de la boquilla de salida del equipo.

Determinación de energía mecánica específica (SME)

SME fue calculada como el total de la energía entregada (Hu *et al* ., 1993), según las ecuaciones siguientes:

$$SME = \frac{n \cdot P \cdot \tau}{n_{max} \cdot Qm \cdot 100} \text{ (kWH/kg)} \quad (5)$$

$$SME_2 = SME_1 * 3600 \text{ (kJ/kg)} \quad (6)$$

donde n es la velocidad de tornillo (RPM), P la potencia (kW), τ el torque (%), n_{max} la velocidad máxima del tornillo (RPM), y Q el flujo másico total (kg/h).

Determinación de propiedades ópticas

Para el análisis del color se empleó un espectro-colorímetro marca Minolta modelo CM-3600d, obteniendo el espectro de reflexión de las muestras entre 380 y 770 nm. Las muestras se acondicionaron para determinar el color, moliendo en forma delicada cada una de ellas y colocándolas en una cubeta de vidrio de 3 cm de diámetro.

Se obtuvieron las coordenadas de color (CIE-L*a*b*) utilizando como referencia el observador 10° e iluminante D65. Los valores de la luminosidad (L*) va en un rango entre 0 y 100, definiendo la claridad de la muestra. La coordenada a* define la desviación hacia el rojo (cuando a*>0) o hacia el verde (cuando a*<0). b* define la desviación hacia el amarillo (cuando b*>0) o hacia el azul (cuando b*<0). Además se calcularon las coordenadas psicométricas: tono (h*_{ab}) y croma (C*_{ab}) aplicando las siguientes relaciones:

$$C^* = \sqrt{a^{*2} + b^{*2}} \quad (7)$$

$$h^* = \arctan\left(\frac{b^*}{a^*}\right) \quad (8)$$

2.4. Análisis Estadístico

El estudio estadístico se inició con los análisis de varianzas (ANOVA) para determinar la influencia significativa de las condiciones de operación (Qm, w y W) en las variables operacionales de respuesta (Tb, Pb y τ) y en las características de producto. Para ello, se utilizó la función "**anovan**" de Matlab R2011b (The Mathworks, 2011), esta función realiza un análisis múltiple de varianza para probar los efectos de múltiples factores en el promedio de la variable dependiente.

Se calculó el valor medio de los errores relativos (ER) (Ec. 9) y los coeficiente de correlación (R) para evaluar la precisión del ajuste (Bon *et al.*, 2010). ER es una medida de la aleatoriedad de la estimación, y R indica la proporción de varianza de los datos que son considerados por cada modelo.

$$ER = \frac{100}{N} \sum_{i=1}^N \frac{|Z_{exp_i} - Z_{cal_i}|}{Z_{exp_i}} \quad (9)$$

Adicionalmente, para probar la bondad de cada modelo, se realizó una prueba estadística t-test para una hipótesis nula con un nivel de significación del 5%, y así demostrar que los valores del vector residual son aleatorios y tienen una distribución normal con media 0 y varianza desconocida, contra la alternativa de que la media no sea 0.

Para probar la hipótesis de que el vector residual proviene de distribuciones normales, se utilizó una prueba Lilliefors, con un nivel de significación del 5%. La función "ttest" de Matlab R2011b se utilizó para realizar la prueba estadística t-test. La función "lillietest" de Matlab R2011b se utilizó para realizar la prueba Lilliefors.

3. SIMULACIÓN y RESULTADOS

ANN₁: Modelo red neuronal para variables medibles

Para construir la ANN₁, se utilizaron los resultados de 24 pruebas experimentales de extrusión (Tabla 3). Estos valores fueron considerados como la matriz de resultados para ajustar el modelo.

TABLA 3. Valores experimentales y los estimados a través de la red neuronal ANN₁.

Nº Muestra	INPUT			OUTPUT EXPERIMENTALES			OUTPUT ESTIMADOS (ANN)		
	Qm (Kg/h)	n (RPM)	W (% bh)	Tb (°C)	Pb (bar)	τ (%)	Tb (°C)	Pb (bar)	τ (%)
1	2	100	20	105	70	30	106	68	30
2	2	100	30	103	47	23	103	46	23
3	2	200	10	108	75	33	108	78	36
4	2	250	10	111	95	39	110	93	40
5	2	250	10	110	81	35	110	93	40
6	5	150	15	109	89	41	110	86	40
7	5	200	15	110	75	43	110	72	42
8	5	200	25	108	65	33	108	60	38
9	5	200	30	108	57	30	107	59	35
10	5	250	15	112	68	45	110	71	43
11	5	250	10	113	120	48	112	115	47
12	5	200	10	111	110	43	111	110	45
13	7	150	20	108	73	39	109	72	42
14	7	150	25	109	65	37	108	67	39
15	7	200	20	112	81	42	110	79	44
16	7	200	25	108	71	41	109	71	40
17	7	250	10	115	124	53	114	112	55
18	7	250	25	108	74	43	109	74	42
19	7	300	10	116	116	61	115	121	60
20	7	200	10	113	118	50	113	116	52
21	9	250	15	116	125	61	115	120	59
22	9	250	30	109	75	43	110	78	43
23	9	250	10	117	147	69	118	145	69
24	9	300	10	119	152	74	119	152	71

En la tabla 4 se muestran los resultados del estudio de ANOVA que se llevó a cabo para analizar la influencia de las condiciones de operación sobre las variables medibles. A partir del estudio se deduce que todas las condiciones de operación consideradas tienen una influencia significativa sobre Tb, Pb y τ (p < 0,05).

El modelo de ANN₁ con 2 capas ocultas y 5 neuronas por cada una de ellas y una capa de salida, mostró un ajuste con suficiente exactitud entre los resultados simulados y experimentales (Figuras 2 y 3), resultando con un coeficiente de correlación global de 0,996, 0,998 entre los datos empleados para el ajuste de la red, 0,994 para validación y 0,994 para prueba o test. El valor de ER fue de 2,98% para el global, mientras que en cada variable de salida los valores de ER fueron 0,74%, 3,5% y 4,65% respectivamente.

TABLA 4. Influencia de las condiciones de operación sobre las variables de salida medibles (ANOVA)

		ANÁLISIS DE VARIANZA ANN 1					
		Output 1					
		Tb		Pb		τ	
		p	F	p	F	p	F
Input	Flujo másico (Qm)	0	42,52				
	Velocidad Husillos (n)	0,0013	11,27	0,0303	5,44	0,0198	6,42
	Humedad (W)	0	49,26	0	79,36	0	97,46
	Combinación (Qm*n)			0	50,42	0	200,95

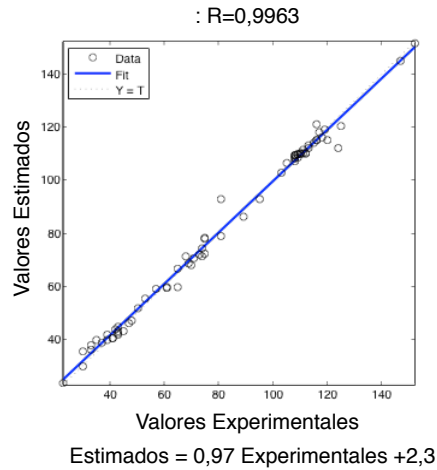


FIGURA 2. Bondad de ajuste global entre datos experimentales y estimados $r = 0,996$.

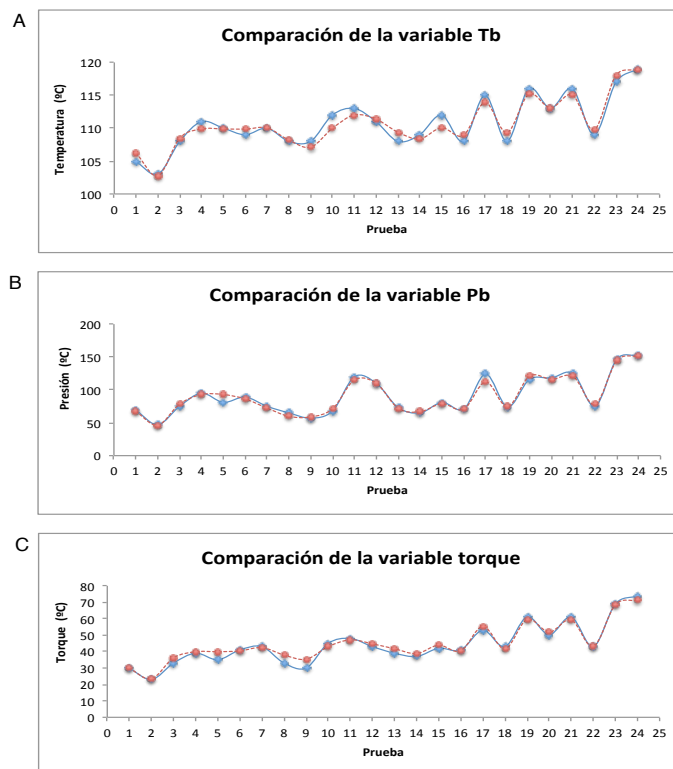


FIGURA 3. Ajuste de cada variable respuesta con su valor experimental, en cada prueba.

En cuanto a la distribución de los valores residuales, la prueba t-test rechaza la hipótesis nula, por lo que es cero el valor medio del vector residual, con un nivel predeterminado de significación de 0,05. Para la prueba Lilliefors, los valores estadísticos son menores que los valores críticos, por lo que se rechaza la hipótesis nula correspondiente, con un nivel de significación 0,05, comprobando la normalidad de los residuales (Tabla 5).

TABLA 5. Pruebas estadísticas de bondad del ajuste. Para valores de $kstat < critval$ los errores siguen una distribución normal.

OUTPUT Variable	lillietest				ttest			
	h	p	kstat	critval	h	pt	ci	
Temperatura boquilla	0	0,50	0,10	0,18	0	0,65	-0,33	0,51
Presión boquilla	0	0,26	0,16	0,18	0	0,49	-1,23	2,48
Torque	0	0,28	0,17	0,18	0	0,09	-1,75	1,14

ANNs₂: Modelos redes neuronales para parámetros de calidad

Para construir el conjunto de modelos ANNs₂, se utilizaron los resultados de 24 determinaciones experimentales (Tabla 5). Estos valores fueron considerados como la matriz de destino para el modelado de cada propiedad.

En la tabla 6 se muestran los resultados de los estudios de ANOVA desarrollados para analizar la influencia de las condiciones de operación manipulables sobre las características del producto. Según los resultados, la influencia de las variables manipulables sobre SME, EI, BD, Xw, es significativa en forma individual o en conjunto ($p < 0,05$), mientras que para el caso de WA, se observó que sólo es influenciada por Qm, y para los parámetros de color, L* es afectado por n y W, C* por Qm y n, y para H* tan solo por Qm. Por lo tanto, para cada característica se desarrolló una ANN, considerando, en cada caso, como variables de entrada las condiciones de operación con una influencia significativa.

TABLA 6. Influencia de las condiciones de operación sobre las variables de salida no medibles (ANOVA)

ANÁLISIS DE VARIANZA ANNs 2																		
Output 2																		
		SME		EI		BD		WA		W		L		C*		H*		
		p	F	p	F	p	F	p	F	p	F	p	F	p	F	p	F	
Input	Flujo másico (Qm)	0,000	60,36	0,003	11,730	0,000	40,75	0,005	10,19			0,485	0,51	0,036	5,06	0,002	12,47	
	Velocidad Husillos (n)	0,000	32,16	0,001	14,270	0,000	100,28	0,013	7,37	0,001	16,65	0,008	8,69	0,023	6,03	0,362	0,87	
	Humedad (W)	0,001	10,54	0,000	29,430			0,061	3,94	0,005	9,98	0,009	8,36	0,137	2,40	0,411	0,71	
	Combinación (Qm*n)					0,000	41,55											
	Combinación (Qm*W)					0,001	16,03			0,013	7,39							

El conjunto de modelos seleccionados se detallan en la tabla 7, mostrando buena bondad de ajuste en todos los casos ($R \geq 0.961$; $ER \leq 8.72\%$), como se observa en la figura 4.

TABLA 7. Características ANNs en modelación parámetro de calidad. CO: capa oculta, n/CO: número de neuronas por capa oculta.

OUTPUT Variable	ESTRUCTURA RED				COEFICIENTES CORRELACIÓN				ERRORES
	Input	CO	n/CO	Cout	modelo	ajuste	validación	prueba	Prom. Errores Abs.
Energía mecánica específica (SME)	3	1	4	1	0,995	0,996	1,000	1,000	3,95%
% expansión (EI)	3	2	6,3	1	0,961	0,959	0,992	0,978	8,72%
Densidad aparente (BD)	3	1	4	1	0,996	0,999	0,984	0,996	5,53%
Capacidad retención agua (WA)	2	2	4,5	1	0,991	0,993	0,986	0,999	5,52%
Humedad (Xw)	3	2	5,3	1	0,986	0,991	0,997	0,999	5,90%
Propiedades ópticas (L*, C*, H*)	3	2	4,5	1	0,998	0,997	1,000	0,998	4,90%

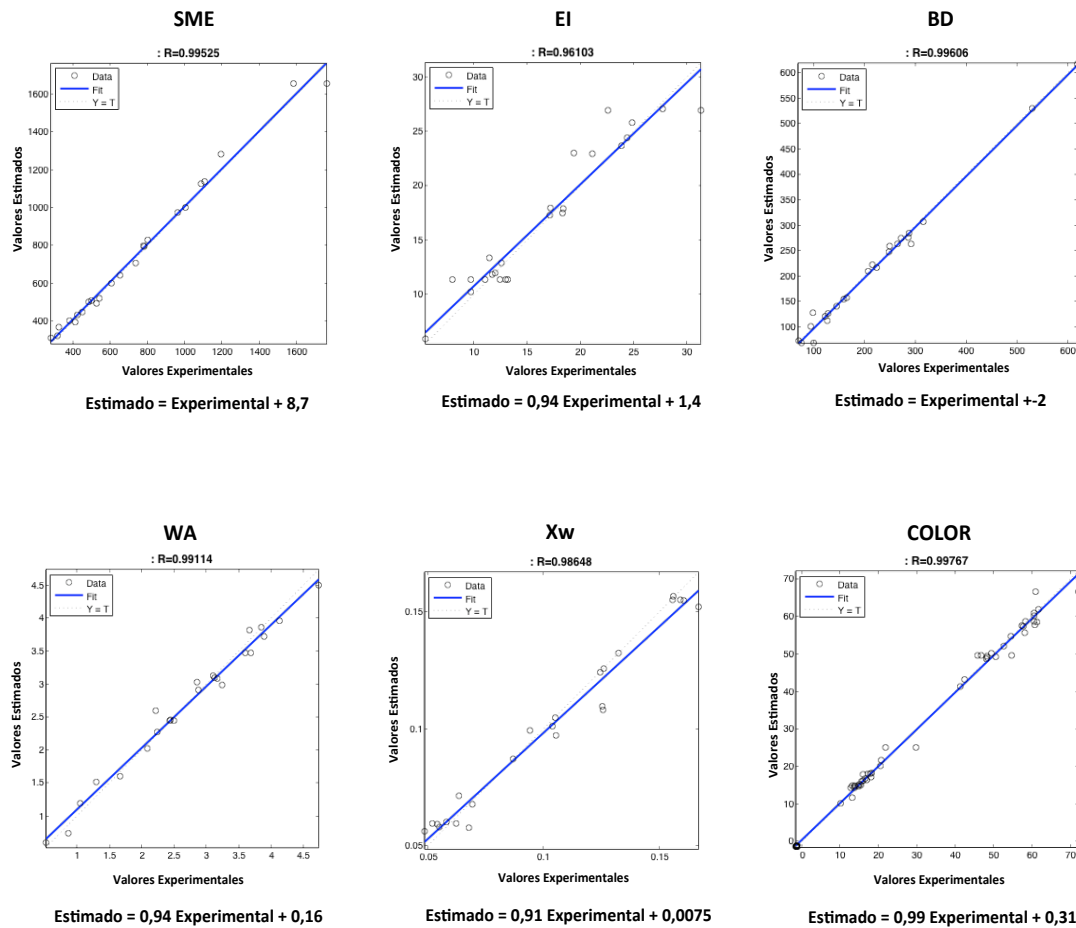


FIGURA 4. Gráficas de ajustes para modelos de parámetros de calidad.

En cuanto a la distribución de los valores residuales, la prueba t-test rechaza la hipótesis nula en cada uno de los casos, con un nivel predeterminado de significación de 0,05 (Tabla 8). Para la prueba Lilliefors, los valores estadísticos son menores que los valores críticos (Tabla 8), rechazándose entonces la hipótesis nula correspondiente, con un nivel de significación 0,05, comprobando la normalidad de los residuales para cada grupo de datos.

TABLA 8. Pruebas estadísticas de bondad de los ajustes. Para valores de $kstat < critval$ los errores siguen una distribución normal.

OUTPUT Variable	lillietest				ttest			
	h	p	kstat	critval	h	pt	ci	
Energía mecánica específica (SME)	0	0,40	0,13	0,18	0	0,18	-0,03	0,01
% expansión (GE)	0	0,08	0,17	0,18	0	0,17	-0,09	0,02
Densidad aparente (DB)	0	0,05	0,15	0,18	0	0,52	-0,03	0,06
Capacidad retención agua (WA)	0	0,34	0,13	0,18	0	0,59	-0,05	0,08
Humedad (Xw)	0	0,07	0,17	0,18	0	0,85	-0,03	0,04
Propiedades ópticas L*	0	0,18	0,15	0,18	0	0,84	-0,02	0,02
Propiedades ópticas C*	0	0,50	0,11	0,18	0	0,17	-0,05	0,01
Propiedades ópticas H*	0	0,30	0,14	0,18	0	0,27	-0,02	0,07

TABLA 5. Valores experimentales y los estimados a través de la redes neuronales ANN₂.

Nº Muestra	INPUT			OUTPUT EXPERIMENTALES									OUTPUT ESTIMADOS (ANNs)								
	Qm (Kg/h)	n (RPM)	W (% bh)	SME (kJ/kg)	GE	DB (g/l)	WA	Xw (%)	L*	C*	H*	SME (kJ/kg)	GE	DB (g/l)	WA	Xw (%)	L*	C*	H*		
1	2	100	20	483,13	11,47	617,88	0,86	12,5%	41,31	10,09	-1,34	498,90	13,33	617,51	0,73	12,4%	41,24	10,16	-1,19		
2	2	100	30	324,10	5,42	530,21	0,53	15,9%	42,44	13,14	-1,46	367,11	5,89	529,73	0,59	15,5%	43,28	11,69	-1,20		
3	2	200	10	1195,74	17,15	287,05	1,30	10,5%	49,36	15,56	-1,38	1284,16	17,25	284,62	1,51	9,7%	50,12	16,00	-1,34		
4	2	250	10	1766,43	31,36	100,10	3,67	6,2%	72,04	29,73	-1,53	1658,26	26,90	69,41	2,44	6,0%	66,70	24,97	-1,39		
5	2	250	10	1585,26	22,58	75,37	3,67	5,2%	61,03	21,75	-1,44	1658,26	26,90	69,41	2,44	6,0%	66,70	24,97	-1,39		
6	5	150	15	526,27	12,60	247,51	0,38	10,5%	54,56	14,91	-1,35	492,03	12,83	248,06	1,19	10,5%	54,72	14,69	-1,25		
7	5	200	15	735,92	18,35	165,13	3,25	9,4%	61,28	20,42	-1,40	703,72	17,42	157,73	2,98	9,9%	58,45	20,19	-1,36		
8	5	200	25	498,33	13,21	215,64	1,69	12,6%	48,08	13,65	-1,35	506,59	11,32	221,80	2,02	10,8%	48,77	14,28	-1,22		
9	5	200	30	422,82	9,71	285,62	1,27	13,2%	54,79	15,49	-1,40	432,09	10,18	275,90	1,60	13,3%	49,57	14,96	-1,22		
10	5	250	15	962,68	23,86	145,47	2,09	10,4%	60,58	20,66	-1,41	973,25	23,63	140,59	2,60	10,1%	60,27	21,67	-1,37		
11	5	250	10	1087,26	27,72	70,74	4,17	4,9%	57,43	16,00	-1,31	1125,07	27,08	72,88	3,86	5,6%	57,59	17,77	-1,35		
12	5	200	10	779,20	24,84	97,78	4,82	6,4%	58,13	17,38	-1,33	796,93	25,82	127,97	3,72	7,1%	55,64	18,13	-1,36		
13	7	150	20	314,08	9,75	291,30	2,64	15,6%	46,75	13,06	-1,33	317,94	11,33	262,61	2,27	15,5%	49,57	14,84	-1,22		
14	7	150	25	279,35	11,96	271,30	2,75	15,6%	48,27	13,64	-1,34	306,66	11,94	274,33	2,46	15,7%	49,45	14,92	-1,22		
15	7	200	20	450,98	11,06	249,81	3,08	12,6%	52,68	15,04	-1,34	445,87	11,33	259,48	2,91	12,6%	52,03	15,18	-1,23		
16	7	200	25	412,73	12,43	314,81	3,17	16,7%	45,82	14,55	-1,42	393,00	11,32	306,42	3,08	15,2%	49,58	14,91	-1,22		
17	7	250	10	800,29	19,36	126,48	3,67	6,8%	60,87	16,88	-1,33	826,18	22,98	112,34	3,81	5,8%	57,80	16,43	-1,35		
18	7	250	25	541,08	12,96	207,04	5,08	12,5%	48,38	12,70	-1,29	516,68	11,32	209,37	3,13	11,0%	49,03	14,18	-1,22		
19	7	300	10	1105,31	24,42	93,89	5,35	5,4%	57,78	15,99	-1,30	1138,61	24,40	100,87	4,49	5,9%	57,47	16,17	-1,35		
20	7	200	10	606,41	21,10	128,15	3,60	6,9%	58,26	17,97	-1,34	597,99	22,91	126,22	3,47	6,8%	58,76	17,08	-1,35		
21	9	250	15	652,48	11,74	223,70	2,50	8,7%	60,68	17,83	-1,35	641,07	11,81	217,29	3,03	8,7%	61,06	17,96	-1,35		
22	9	250	30	378,78	7,99	264,81	3,33	16,1%	50,49	13,92	-1,31	400,77	11,32	263,02	3,10	15,5%	49,21	14,69	-1,22		
23	9	250	10	781,47	17,17	159,07	3,68	5,8%	61,78	18,28	-1,34	795,02	17,93	155,07	3,48	6,0%	61,99	18,30	-1,36		
24	9	300	10	1003,00	18,42	121,85	4,13	5,5%	60,63	16,49	-1,31	1001,83	17,89	121,51	3,95	5,8%	58,69	16,71	-1,35		

4. CONCLUSIONES

Todas las condiciones de operación consideradas tienen influencia significativa sobre las variables de salida SME, EI, BD y Xw, mientras que la variable WA sólo es influenciada por Qm, el parámetros de color L* es afectado por n y W, el parámetro C* por Qm y n, y el parámetro H* tan solo por Qm.

El presente trabajo permitió comprobar que las ANNs modelan adecuadamente el proceso de extrusión, un ejemplo de procesos alimentarios de gran complejidad, donde se presentan fenómenos como, por ejemplo, gelatinización de almidones, desnaturalización de proteínas y cambios estructurales que afectan a las propiedades físicas.

Las ANNs desarrolladas permiten simular adecuadamente la influencia de las condiciones de operación sobre las variables medibles y las características de calidad del producto consideradas. Por consiguiente, tales ANNs pueden ser empleadas para simular el funcionamiento del extrusor disponible en AINIA, y para formular y resolver problemas de optimización del funcionamiento del mismo en función de los objetivos perseguidos.

NOMENCLATURA

ANN	Red neuronal artificial	
ANN ₁	Red neuronal desarrollada para predecir variables de respuesta medibles	
ANN ₂	Red neuronal desarrollada para predecir variables de respuesta no medibles	
a*	Parámetro color de relación rojo - verde	
b*	Parámetro color de relación amarillo - azul	
BD	Densidad aparente producto	g/L
C*	Coordenada psicométrica Tono	
D	Diámetro husillos	m
Dd	Diámetro de boquilla	mm
De	Diámetro de estrusado	mm
EI	Grado de expansión	%
ER	Errores relativos	%
h*	Coordenada psicométrica Cromo	
L	Longitud de husillos	m
L*	Parámetro color Luminosidad	
L/D*	Razón Longitud/Diámetro husillos	
m _{agua}	Masa agua presente en la muestra	g
m _{crisol}	Masa de crisol seco	g
m _{final}	Masa muestra luego de sumergida	g
m _{humeda}	Masa de muestra inicial + crisol seco	g
m _{inicial}	Masa inicial antes de sumergir	g
m _{muestra}	Masa muestra	g
MSE	Errores cuadráticos medios	
m _{seca}	Masa de muestra seca + crisol seco	g
n	Velocidad de rotación de husillos	RPM
N	Número de observaciones	
n _{max}	Velocidad máxima de rotación de husillos	RPM
P	Potencia del motor	kW
p	Probabilidad	

Pb	Presión en boquilla	bar
Q	Flujo másico total	kg/h
Qm	Flujo másico seco de materia prima	kg/h
R	Coeficiente de correlación	
SME	Energía mecánica específica	kJ/kg producto
τ	Torque par de motor	%
Tb	Temperatura de salida en boquilla	°C
V _{contenido}	Volumen estandar para medición de BD	L
W	Cantidad de agua en matriz	%
WA	Capacidad retención agua producto	%
Xw	Contenido de humedad en producto final	kg H ₂ O/kg producto
Z _{cal}	Valor calculado	
Z _{exp}	Valor experimental	

5. REFERENCIAS

Alvarez-Martinez, *et al.* (1988). A general model for expansion of extruded products. *Journal of Food Science*, 53, 609 - 615.

A.O.A.C. (2000). *Official Methods of Analysis of AOAC International* (17th edition). Gaithersburg, MD, USA.

Bon, J. *et al.* (2010). Thermophysical properties of mango pulp (*Mangifera indica* L. cv. Tommy Atkins). *J. Food Eng.* 97, 563-568.

Cheng and Friis. (2010). Modelling extrudate expansion in a twin-screw food extrusion cooking process through dimensional analysis methodology. *Food and bioproducts processing* 88, 188 -194.

Eerikainen, T., Zhu, Y.-H. and Linko, P. (1994). Neural networks in extrusion process identification and control. *Food Control*, 5, 111 - 119.

Ficarella, A. *et al.* (2006). Numerical study of the extrusion process in cereals production: Part I. Fluid-dynamic analysis of the extrusion system. *Journal of Food Engineering* 73, 103 - 111.

Goñi, S.M. *et al.* (2008). Prediction of foods freezing and thawing times: Artificial neural networks and genetic algorithm approach. *J. Food Eng.* 84 164–178.

Guy, R. (2001). *Extrusion Cooking Technologies and applications*. CRC Press.

Haley, T.A. and Mulvaney, S.J. (1995). Advanced process control techniques for the food industry. *Trends Food Sci. Technol.* 6, 103 - 110.

Haykin, S. (1994). *Neural Networks. A Comprehensive Foundation*, IEEE Press.

Hu, L., Hsieh, F., & Huff, H. E. (1993). Corn meal extrusion with emulsifier and soybean fibre. *LWT – Food Science and Technology*, 26, 544 - 551.

Kumar *et al.* (2008). Modeling residence time distribution in a twin-screw extruder as a series of ideal steady-state flow reactors. *Journal of Food Engineering* 84, 441 - 448.

Levenberg, K.A., (1944). Method for the solution of certain non-linear problems in least squares. *Q. J. Appl. Math.* 2, 164-168.

Li, C. (2001). Modelling Extrusion Cooking. *Mathematical and Computer Modelling* 33, 534 - 563.

Mercier, C., Link, P. and Harper, J.M. (1989). *Extrusion Cooking*, American Assoc. Cereal Chemists, USA.

Moya de la Torre, A. (2005). Modelado y simulación de un proceso de extrusión. ETSII y Fundación CARTIF.

Neelam, S. *et al.* (2006). Modeling of extrusion process using response surface methodology and artificial neural networks. *Journal of Engineering Science and Technology* vol. 1, nº 1, 31- 40.

Popescu, O, *et al.* (2000). A new approach to modeling and control of a food extrusion process using artificial neural network and an expert system. *Journal of Food Process Engineering*, 24, 17 - 36.

Rattaray, J. y Floros J.D. (1999). Neural network predictive process modelling: Applications to food processing. AIChE Annual Meeting, Dallas, Texas.

The Mathworks. (2011). *Matlab user's guide*. The MathWorks Inc., South Natick, MA, USA.

Wang, L. *et al.* (2006). Modeling of Transport Phenomena and Melting Kinetics of Starch in a Co-Rotating Twin-Screw Extruder. *Advances in Polymer Technology* 25, 22 - 40.