

Rendimiento Quesero

SU PREDICCIÓN COMO UNA HERRAMIENTA PARA EVALUAR EL PROCESO DE ELABORACIÓN.

Resumen: No existe consenso en el modo de predecir el rendimiento quesero. En la actualidad, las ecuaciones disponibles se basan en un balance de masa de componentes que incluyen coeficientes de transferencia y/o retención de un componente en queso o suero, sin considerar desviaciones provocadas por las condiciones de procesamiento, siendo estas tan complejas y diversas que hacen imposible desarrollar un modelo matemático que incluya factores fisicoquímicos, tecnológicos y humanos. En el trabajo, se estudió el rendimiento quesero de queso Cremoso Argentino con datos provistos por la planta piloto de la ESIL situada en Villa María. Se modeló e implementó una red neuronal para predicción de rendimiento basado en datos de composición de la leche, comparando el rendimiento real y el predicho.

Finalmente, se probó la capacidad de predicción del modelo desarrollado y su aplicación a nivel industrial, demostrándose su aptitud para obtener predicciones precisas de la dimensión Rendimiento Quesero.

Palabras Claves: Rendimiento quesero, composición láctea, redes neuronales artificiales, inteligencia artificial.

Abstract: There is not consensus concerning the correct way to predict cheese yield. Actually, the equations available are based on a mass balance of the components including transfer coefficients and / or retention of, regardless of the deviations caused by the processing conditions, these being so complex and diverse that make it impossible to develop a mathematical model able of including all factors involved: physicochemical, technological and human.

In this work, the cheese yield of a creamy cheese, provided by the ESIL pilot plant, Villa Maria, was studied. The evaluation was performed with A neural network for predicting cheese yield using milk composition data, and comparing the predicted and real yield.

Finally, the capability of cheese yield prediction with a neural network model was better than mass balance methods and suggests it could be expanded to the industrial level.

Keywords: Cheese yield; Milk composition; Artificial Neural Network; Artificial Intelligence.

Rubén L. Baccifava⁽¹⁾ - Jorge Palombarini⁽²⁾ - Silvia C. Kivatinitz⁽³⁾

(1)(2) UTN FR Villa María, Dpto Ing. Química, Av. Universidad 450, Villa María, Argentina.

(3) UNC, Dpto. Química Biológica-CIQUIBIC, Av. Haya de la Torre s/n, Córdoba, Argentina.

Mail: rubenbaccifava@hotmail.com

INTRODUCCIÓN Y OBJETIVOS

Para los fabricantes de quesos, optimizar el rendimiento no debería significar solamente recuperar la máxima cantidad posible de los componentes de la leche, sino también poner en práctica estrategias eficaces y eficientes para satisfacer sus propósitos, los de sus clientes y los de sus proveedores, principalmente los productores de leche, es decir aplicar la definición de Calidad como: "La facultad de un conjunto de características inherentes de un producto, sistema o proceso para cumplir con los requisitos de los clientes y de otras partes interesadas".

De esa manera, la optimización del rendimiento no se lo considera como un tópico aislado y eminentemente tecnológico, sino que adquiere su sentido más amplio y profundo cuando se le considera como un asunto interrelacionado integralmente con los atributos de calidad del queso y con la visión de un negocio sustentable a mediano y largo plazo.

La tarea de optimizar el rendimiento podría reducirse a un esquema simplificado de búsqueda de tecnología para aumentar la relación humedad/proteína en los quesos. Entonces, optimizar el rendimiento en la elaboración de quesos es un reto que consiste esencialmente en maximizar la cantidad y la calidad, a la vez, como un todo, Emmons (2003), Dalla Costa (2012).

Especificaciones de Producto y Proceso

Una vez que los requerimientos de los clientes han sido traducidos en especificaciones que se encuadran con las definidas en el Código Alimentario Argentino, y luego de definir especificaciones propias de producto (calidad de las materias primas e insumos y procedimientos operacionales), logrando que los productos y servicios se ajusten a los deseos y expectativas de los clientes, se debe ante todo reducir la variación; es

decir, mantener una calidad estable en el tiempo, CAA, SAGPyA y SPRyRS (2006).

Una característica particular en la elaboración de quesos, consiste en que independientemente de la tecnología empleada (asociada generalmente al sector al que pertenezca la empresa: PyME o grande), conserva siempre aspectos artesanales en alguna instancia del proceso que son difíciles de eliminar con la incorporación de tecnología, o bien el costo de ésta lo hace inviable económicamente como describe Inda Cunningham (2000).

Variabilidad del Producto y Proceso

En toda empresa siempre habrá variaciones en el proceso productivo, introducidas por el personal y su forma de trabajar, relacionadas con los aspectos artesanales de la elaboración arriba mencionados, las materias primas (particulares y estacionales) Gilles (1985), Lawrence (1996), Pécora et al. (2008), el funcionamiento de los equipos, el medio ambiente físico y las condiciones psicológicas del personal, las mediciones de costos, o los controles de laboratorio y de rendimientos, Alais (1985), Vicente Madrid (1999). Estas variaciones, influirán en la calidad final de los productos y en su variabilidad, poniendo en evidencia la complejidad para definir calidad en una empresa elaboradora de quesos, Lolkema (1993) y demostrando que mantener y minimizar su variabilidad en el tiempo es una tarea aún más compleja IL-IDF, F.I.D.L. (1993), Aytug et al. (2005).

Integrar una herramienta que mejore la predicción del rendimiento con el control estadístico del proceso, permitiría controlar la variabilidad del proceso a través de la posibilidad de establecer indicadores, AENOR (2003) que contemplen el rendimiento predicho y los rendimientos reales y de este modo permitir analizar

y resolver las causales de estas desviaciones en una segunda instancia, Jimenez-Marquez (2002).

En el presente trabajo se pretende evaluar y aplicar herramientas estadísticas y de modelado de redes neuronales a la industria quesera.

Objetivo del Trabajo

Determinar la capacidad de una Artificial Neural Network (ANN) para predecir el rendimiento de producción de quesos considerando sólo aspectos químicofisicos y permitir una mejora en evaluación del desempeño del proceso, mediante la comparación entre el rendimiento real obtenido y el predicho por ANN.

METODOLOGÍA

Definición del Objeto de Estudio y las Unidades de Análisis

El objeto de estudio de esta investigación fue el rendimiento quesero (RQ) en el proceso de elaboración de quesos.

Las unidades de análisis fueron elaboraciones de queso realizadas en la planta piloto de la Escuela Superior Integral de Lechería (ESIL), donde intervienen alumnos que cursan el 5to y 6to año del ciclo de especialización de la ESIL.

Como se desprende de este trabajo exploratorio, existe un número significativo de variables dependientes que determinan el rendimiento quesero, a los fines prácticos se considerara el conjunto de variables continuas relacionadas a la calidad de la materia prima empleada, es decir la composición química de aquellos componentes de la leche que tienen incidencia sobre el rendimiento quesero y que son aquellas que

la bibliografía emplea en el modelado de ecuaciones para la predicción del rendimiento quesero.

Descripción de la Muestra de Datos

Se han seleccionado 1407 datos de elaboración de queso Cremoso, extraídos de los registros de elaboración que posee la planta piloto de la ESIL, realizadas en el período 2006-2014, periodo que no refleja cambios significativos en el proceso ya que se dispone del mismo equipamiento como se evidenció en las entrevistas con el responsable técnico de la planta.

Descripción de Técnicas e Instrumentos de Recolección, Medición, Procesamiento y Análisis de Datos

Los datos composicionales fueron analizados en el laboratorio con el que cuenta la institución, y están disponibles en los registros de producción. Los datos fueron procesados en una planilla de Excel y luego validados mediante un control posterior. El rendimiento quesero se determinó en kg de queso / 100 kg de leche.

Con un análisis primario de los datos de origen de planta piloto se pudo observar la presencia de datos poco significativos respecto a las propiedades estadísticas de la muestra, por lo cual se definió un proceso de depuración de dichos datos y se alcanzó un tamaño de muestra de 1135 elaboraciones que cumplían los criterios de selección que se establecieron, de los cuales se tomaron para el presente trabajo un subconjunto de 1000 elaboraciones como datos de partida (DP) que corresponde a elaboraciones del año (2007 a 2014) en la planta de elaboración de quesos de la ESIL, para el producto Queso Cremoso.

Luego se procedió a modelar una ANN que predice el rendimiento quesero y se seleccionó el mejor modelo que predice dicho rendimiento.

RESULTADOS Y DISCUSIÓN

Relevamiento del Conjunto de Datos del Proceso

La complejidad de variables que intervienen con mayor o menor peso sobre el rendimiento quesero hace que los modelos actuales posean una simplicidad que no se corresponde con las dimensiones que definen el rendimiento quesero, principalmente los aspectos referidos al proceso de elaboración. El empleo de un parámetro difícil de predecir como lo es el RQ, para la evaluación y seguimiento de un proceso, a través del rendimiento real y el predicho, que se obtiene en cada lote de producción puede ocasionar dificultades al momento de evaluar la eficiencia de un proceso, pudiendo en muchos casos arribar a conclusiones erróneas.

Se procedió al análisis conjunto DP de 1000.

Como se mencionó, existen muchos factores que afectan el rendimiento quesero y se podrían reunir en grupos, según la característica principal a la que se refieren, a continuación se detallan los principales.

Referidos a la materia prima: materia grasa, proteínas y fracción de caseína (dato no disponible), lactosa (no disponible), cenizas (no disponible), cuajo, y fermentos empleados y proceso de estandarización. Algunas de estas variables están analizadas por el laboratorio de calidad de la FUNESIL y se encuentran detallados para cada lote de producción, otras variables se encuentran disponibles pero no con la frecuencia que se requiere, sólo son ensayos puntuales.

Referidos al proceso de elaboración en tina: operario, tamaño del grano, temperatura de coagulación, pH Inicial, Cantidad de Cl2Ca empleado, punto final de la coagulación, aspectos relativos al diseño de la herramienta de corte, velocidad de agitación,

tamaño de grano alcanzado.

Referidos al proceso de terminación: condiciones prensado (tiempo, presión, temperatura, etc.), condiciones salado (concentración, tiempo, pH y temperatura), condiciones de maduración (tiempo, temperatura y humedad).

A partir de lo anterior, se realizó una revisión de los datos disponibles asociados a cada lote de producción, el modo de cómo se llevan a cabo las elaboraciones y una la revisión de la tecnología disponible entrevistando los responsables de la planta.

Se recopilaron datos disponibles de la materia empleada de cada lote de producción, a saber: Volumen de leche empleada (litros), Cantidad de Crema extraída para estandarizar contenido de MG de la leche, Materia Grasa [% w], Proteínas [% w], SNG [% w], Peso de Producto [kg], Peso de Recortes [kg].

Análisis Primario del Problema

En primera instancia se realizó la digitalización de los datos recopilados. El total de elaboraciones procesadas fue de 1407 elaboraciones, que correspondieron a los datos originales (DO).

Se realizó un tratamiento sobre los datos originales, efectuando un análisis de las variables %MG, %PR y %SNG y rendimiento real. Se realizó el cálculo de los límites de control inferior (LCI) y el límite de control superior (LCS), tomando un intervalo de confianza de ±3 σ (Ver Tabla 1).

El subconjunto de DO de composición química, se depuró y se descartaron elaboraciones fuera de los respectivos intervalos de confianza definidos para cada dimensión. Los datos depurados (DD), quedando reducido a un total de 1135 elaboraciones, del conjunto de datos DD, se seleccionaron los 1000 primeros elementos a los que se llama datos de partida (DP) y se realizó una mezcla aleatoria de los datos, con el fin

de evitar posibles tendencias en el tiempo, ya que los datos fueron procesados en forma correlativa y corresponden a un período largo de tiempo (Ver Tabla 2).

Variación de los Rendimientos Queseros en Función de los Componentes Químicos de la Leche

Se analizó la variación del rendimiento quesero real en función del contenido de materia grasa, proteína, y sólidos no grasos. El análisis estadístico de datos apareados de rendimiento quesero en función de materia grasa, proteínas, lactosa y sólidos totales, mostró una correlación significativa con proteínas, materia grasa y con sólidos totales, como se muestra en la Tabla 3. Se observó claramente la dependencia fuerte con Prot. y SNG como se observa en la Figura 1, y en menor medida con MG.

Implementación de Algoritmo en MATLAB

Para correlacionar y predecir el rendimiento quesero utilizando un modelo ANN se codificaron los siguientes archivos:

- Un archivo de Excel que contiene las variables independientes: %MG, %SNG v %PR.
- Un archivo de Excel que contiene la variable dependiente: Rendimiento quesero.
- Un código de MATLAB que consta de cinco bloques, cada bloque contiene dos partes:
 - o Una sección de entrenamiento.
 - o Una sección de predicción.

En la sección de entrenamiento el programa lee los datos de entrada (los dos archivos de Excel), define la

Dimensión	Promedio	Desv.Est.	LCI	LCS
Materia Grasa [% p/v]	3.5365	0.2385132	2.8209	4.2520
Proteínas Totales [% p/v]	3.2035	0.1593218	2.7416	3.6652
Sólidos No Grasos [% p/v]	8.5234	0.4049993	7.3084	9.7384
Rendimiento Real	14.2147	0.0101913	11.1573	17.2721

Tabla 1: variables y límites de control..

Conjunto de datos	Sigla	Cantidad
Datos Originales	DO	1407
Datos Depurados	DD	1135
Datos de Partida	DP	1000
Subconjunto DP p/Entrenamiento	DP-E	
Subconjunto DP p/Validación	DP-V	

Tabla 2: Resumen de los conjuntos de datos.

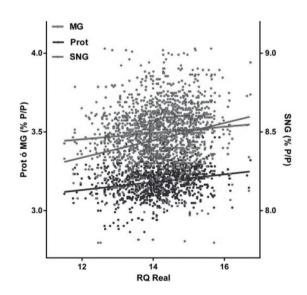


Figura 1: Correlación RQ vs MG, Prot y SNG.

arquitectura, define la función de entrenamiento de la red, y se generan las matrices de peso y las matrices de ponderación, para luego almacenar los datos para la predicción.

En la sección de predicción del programa, se carga la configuración de la red entrenada y el archivo de Excel que contiene las concentraciones de Materia Grasa, Sólidos No Grasos y Proteínas, y luego los resultados se almacenan en un archivo de salida.

La Figura 3 presenta un diagrama de flujo del programa desarrollado para utilizar ANNs. En el mismo se detallan las conexiones entre el código de programa y los archivos de Excel que contienen la información necesaria para el entrenamiento y la predicción. Dicho diagrama es útil para una mejor comprensión del código desarrollado.

Best-fit values	%MG [w]	%SNG [w]	%Prot [w]
Slope	0,01985 ± 0,005784	0,05499 ± 0,007591	0,02483 ± 0,003231
Y-intercept when X=0.0	$3,215 \pm 0,08226$	$7,677 \pm 0,1080$	$2,833 \pm 0,04596$
X-intercept when Y=0.0	-161.9	-139.6	-114.1
1/slope	50.37	18.18	40.28
95% Confidence Intervals			
Slope	0,008518 to 0,03119	0,04011 to 0,06987	0,01849 to 0,03116
Y-intercept when X=0.0	3,054 to 3,376	7,465 to 7,889	2,743 to 2,923
X-intercept when Y=0.0	-396,4 to -97,92	-196,7 to -106,9	-158,1 to -88,04
Goodness of Fit			
R square	0.01167	0.04995	0.05585
Sy.x	0.1593	0.2091	0.08903
Is slope significantly non-zero?			
F	11.78	52.47	59.03
DFn, DFd	1,000, 998,0	1,000, 998,0	1,000, 998,0
P value	0.0006	< 0,0001	< 0,0001
Deviation from zero?	Significant	Significant	Significant
Data			
Number of X values	1000	1000	1000
Maximum number of Y replicates	1	1	1
Total number of values	1000	1000	1000
Number of missing values	0	0	0
Equation	Y = 0,01985*X + 3,215	Y = 0,05499*X + 7,677	Y = 0,02483*X + 2,833

Tabla 3: Correlación entre rendimiento real y variables independientes.

Predicción de Rendimiento por ANN Entrenada (RQ ANN)

Se realizó el cálculo de predicción del producto Queso Cremoso empleando las variables del conjunto de datos DP: MG [% w], SNG [% w], PR [% w] y Rendimiento Real. (Bose y Liang 1996).

Para ajustar la red neuronal se siguió la siguiente secuencia: (1) Seleccionar un modelo de ANN, (2) Definir el tamaño óptimo para el conjunto de datos (DP-A y DP-V) de entrenamiento de la red y validación de la red; (3) Determinar la topología de la mejor modelo de red neuronal y (4) Decidir la mejor función de aprendizaje para la fase de entrenamiento.

Para la evaluación del comportamiento de las distintas configuraciones de la red neuronal se definió el % de error absoluto promedio (%EAP), entre el valor predicho y el real para el subconjunto de datos DP-V, que corresponde a los datos de validación. Se consideró que menor %EAP corresponde un mejor desempeño de la configuración de ANN, Laurene (1994).

Se empleó el software MATLAB v7.2 R2011a que incluye el modelo de redes neuronales, y se creó un algoritmo que responde al esquema de la Figura 2.

Definición del Modelo de la ANN

Se procedió al análisis del modelo de red neuronal que mejor ajustase los datos disponibles. En ese sentido, la arquitectura más básica utilizada normalmente para este tipo de aplicaciones implica una red neuronal de propagación hacia atrás feed-forward que contiene tres capas: una capa para la matriz de entrada, una capa oculta y otra capa de salida, Zupan y Gasteiger (1993). Esta arquitectura no generó buenos resultados en este caso. Por esta razón, fue necesario

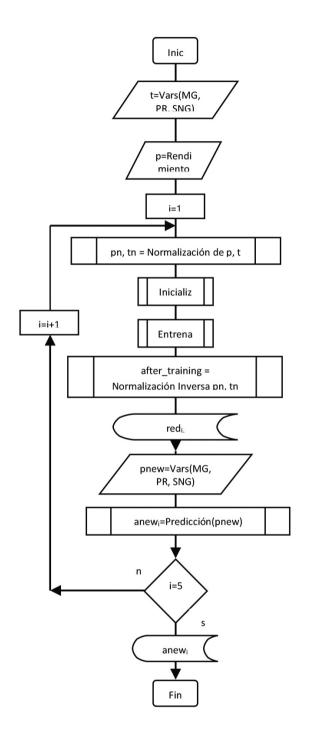


Figura 2: Diagrama de flujo que muestra las conexiones entre los diferentes archivos y programas que forman la ANN.

emplear dos capas ocultas y se evaluaron, entrenaron y optimizaron distintos modelos de redes neuronales feed-forward, Elman, Cascade Forward Backpropagation y Fitnet, Liao (2005).

Para los casos de estudio se determinó el conjunto de datos de entrenamiento en una primera instancia, luego se definió la mejor estructura de la red y posteriormente se seleccionó la mejor función de entrenamiento. Para definir el proceso de entrenamiento se realizaron cinco entrenamientos sucesivos y se seleccionó el que brindaba mejor coeficiente de correlación.

Modelo de Red: Feed-Forward

En el modelo se procedió a determinar el tamaño óptimo de entrenamiento de la red, luego determinar la topología óptima de la red y la mejor función de entrenamiento.

Los parámetros que se emplearon para predecir con ANN, se analizaron distintos tamaños para el conjunto de entrenamiento como se observa en la Tabla 4 y mejor ajuste para el conjunto de datos DP-V corresponde con un conjunto de entrenamiento del 80%.

Se analizaron distintas topología como lo muestra la Tabla 5 emplea una topología de red de 3x6x6x1, es decir, 4 capas de neuronas, 3 neuronas en la capa de entrada, 2 capas ocultas con 6 neuronas y una neurona en la capa de salida.

Se adopta como la función de entrenamiento "trainlm" (ecuación de Levenberg-Marquardt Backpropagation) ya que mejora significativamente la correlación como se puede observar en la Tabla 6.

Posteriormente se analizaron los rendimientos reales, y se calcularon los rendimientos predichos con el modelo de la Prueba 8, Train3 sobre el conjunto de datos DP.

Se empleó el software GraphPad Prism 5.01 para el

análisis estadístico de las variables rendimiento real y rendimiento predicho por ANN8, se muestra en la Figura 3, y se realizó un resumen estadístico de la correlación en la Tabla 8. Es interesante destacar que la pendiente se acercó bastante al valor ideal de 1, siendo r2=0,82885. En la Tabla 7, se puede observar los resultados obtenidos al optimizar otros modelos de ANN.

Prueba	Tamaño de	Coet	Coeficiente de correlación r2 (Rendimiento Real y ANN)				NN)
Prueba	entrenamiento	Train 1	Train 2	Train 3	Train 4	Train 5	Mejor
1	3x6x6x1 - 10%	0.00179	0.12908	0.00002	0.00515	0.03527	0.12908
2	3x6x6x1 - 20%	0.56231	0.46759	0.17634	0.00996	0.01194	0.56231
3	3x6x6x1 - 30%	0.37393	0.52044	0.03661	0.00889	0.40652	0.52044
4	3x6x6x1 - 40%	0.24850	0.07843	0.01498	0.64234	0.01893	0.64234
5	3x6x6x1 - 50%	0.22306	0.56889	0.22710	0.30882	0.00386	0.56889
6	3x6x6x1 - 60%	0.39493	0.04357	0.01338	0.06087	0.01308	0.39493
7	3x6x6x1 - 70%	0.01092	0.05198	0.47593	0.76328	0.00719	0.76328
8	3x6x6x1 - 80%	0.35864	0.08463	0.82885	0.74745	0.00054	0.82885
9	3x6x6x1 - 90%	0.10556	0.80300	0.78848	0.68175	0.76211	0.80300
10	3x6x6x1 - 100%	No se con	No se considera ya que no ofrece modo de validar la capacidad de				
			predicción				

Tabla 4: Determinación del tamaño de muestra para entrenamiento.

Topología de	Coefici	ente de co	rrelación r²	(Rendimie	nto Real y	ANN)
la ANN	Train 1	Train 2	Train 3	Train 4	Train 5	Mejor
3x6x6x1	0.3577	0.4912	0.3609	0.5545	0.5459	0.5545
3x9x9x1	0.0719	0.0234	0.0764	0.0052	0.0086	0.0764
3x12x12x1	overflow					Error
3x18x18x1	overflow					Error
4x8x8x1	0.0194	0.0022	0.0263	0.0112	0.0009	0.0263
5x10x10x1	0.0123	0.0095	0.0558	0.0547	0.0011	0.0558
	la ANN 3x6x6x1 3x9x9x1 3x12x12x1 3x18x18x1 4x8x8x1	la ANN Train 1 3x6x6x1 0.3577 3x9x9x1 0.0719 3x12x12x1 overflow 3x18x18x1 overflow 4x8x8x1 0.0194	la AÑN Train 1 Train 2 3x6x6x1 0.3577 0.4912 3x9x9x1 0.0719 0.0234 3x12x12x1 overflow 3x18x18x1 overflow 4x8x8x1 0.0194 0.0022	Ia ANN Train 1 Train 2 Train 3 3x6x6x1 0.3577 0.4912 0.3609 3x9x9x1 0.0719 0.0234 0.0764 3x12x12x1 overflow verflow 4x8x8x1 0.0194 0.0022 0.0263	Ia ANN Train 1 Train 2 Train 3 Train 4 3x6x6x1 0.3577 0.4912 0.3609 0.5545 3x9x9x1 0.0719 0.0234 0.0764 0.0052 3x12x12x1 overflow 3x18x18x1 overflow 4x8x8x1 0.0194 0.0022 0.0263 0.0112	la ANN Train 1 Train 2 Train 3 Train 4 Train 5 3x6x6x1 0.3577 0.4912 0.3609 0.5545 0.5459 3x9x9x1 0.0719 0.0234 0.0764 0.0052 0.0086 3x12x12x1 overflow 3x18x18x1 overflow 4x8x8x1 0.0194 0.0022 0.0263 0.0112 0.0009

Tabla 5: Determinación de la topología de la ANN.

Ν°	Función de	Coeficiente de correlación r² (Rendimiento Real y ANN)					ANN)
Prueba	Entrenamiento	Train 1	Train 2	Train 3	Train 4	Train 5	Mejor
8	trainIm	0.35864	0.08463	0.82885	0.74745	0.00054	0.82885
21	traingda	0.61824	0.60543	0.58377	0.62964	0.61971	0.62964
22	traincgf	0.69593	0.74801	0.72933	0.70916	0.71161	0.74801
23	Trainrp	0.71602	0.76562	0.67122	0.70280	0.72435	0.76562
24	Traingd	0.21395	0.18132	0.50352	0.23237	0.54884	0.54884
25	trainscg	0.74078	0.69719	0.79235	0.81287	0.76545	0.79235
26	traincgp	0.52704	0.66729	0.68694	0.67666	0.76097	0.76097
27	trainoss	0.72595	0.72340	0.77856	0.69669	0.73977	0.77856
28	traincgb	0.62689	0.62349	0.63344	0.74535	0.77848	0.77848

Tabla 6: Selección de la función de entrenamiento.

Red	Topología	Tamaño	Función de	r ²
		Entrenamiento	Entrenamiento	
Feed-Forward Backpropagation	3x6x6x1	80%	trainLM	0.8288
Elman	3x6x6x1	20%	trainRP	0.6230
Cascade Forward Backpropagation	3x18x1	90%	trainLM	0.7630
Fitnet	3x9x1	70%	trainLM	0.7490

Tabla 7: Resumen de Ajuste de RQ Real según el modelo de predicción.

CONCLUSIONES

El análisis estadístico de datos apareados de rendimiento quesero en función de materia grasa, proteínas, lactosa y sólidos totales, mostró una correlación significativa con proteínas, materia grasa y con sólidos totales (Tabla 3: Correlación entre rendimiento real y variables independientes).

Se optimizaron modelos de predicción basados en una ANN, y se demostró su aptitud para obtener predicciones precisas de la dimensión Rendimiento Quesero (r2=0.8289 para el mejor modelo neuronal).

El modelo desarrollado utiliza datos disponibles en cualquier planta, ya que no es necesario contar con datos físico-químico composicionales que pueden no estar disponibles en la misma, y además permite incorporar otro tipo de variables de interés a nivel industrial.

Finalmente, se logró contar con un rendimiento predicho que permite evaluar el desempeño global del proceso de fabricación mediante su comparación con el rendimiento real, lo cual da lugar al establecimiento de acciones de control para el desarrollo del proceso, y al mismo tiempo provee información para la toma de decisiones en el entorno industrial.

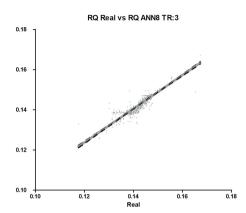


Figura 3: Rendimiento Real vs. ANN.

Estadístico	Valor
Best-fit values	
Slope	0.82885 ± 0.01206
Y-intercept when X=0.0	0.02310 ± 0.001731
X-intercept when Y=0.0	-0.02754
1/slope	1.192
95% Confidence Intervals	
Slope	0.8151 to 0.8624
Y-intercept when X=0.0	0.01971 to 0.02649
X-intercept when Y=0.0	-0.03250 to -0.02286
Goodness of Fit	
r ²	0.8289
Sy.x	0.001673
Is slope significantly non-zero?	
F	4833
DFn. DFd	1.000, 998.0
P value	< 0.0001
Deviation from zero?	Significant
Data	o.goan
Number of X values	1000
Maximum number of Y replicates	1
Total number of values	1000
Number of missing values	0

Tabla 8: Análisis de Regresión RQ Real y RQ ANN8 TR:3.



REFERENCIAS

AENOR (2003). «Guía para la implantación de sistemas de indicadores.» Norma Española UNE 66175. Madrid: AENOR. Alais, Charles (1985). Ciencia de la Leche. Barcelona: Editorial Reverté s.a.

Aytug, Haldun, Mark A. Lawley, Kenneth McKay, Shantha Mohan, y Reha Uzsoy (2005). «Executing production schedules in the face of uncertainties: A review and some future directions.» European Journal of Operational Research, 2005: 161-86–110.

Bose, N.K., y P. Liang (1996). Neural Networks Fundamentals with Graphs, Algorithms. USA: The McGraw-Hill Companies, Inc.

CAA, SAGPyA, y SPRyRS. (2006) «Código Alimentario Argentino.»

Dalla Costa, César Albero (2012). «Rendimiento Quesero Teórico y Real de la Leche de la Cuenca de Villa María, Córdoba.» Tesis de posgrado: Magister en tecnología de los alimentos. Córdoba: http://pa.bibdigital.uccor.edu. ar/665/1/Tesis_RQ_Final_CDC_15_IMPRIMIR.pdf.

Emmons, D.B., C. Dubé, and H.W. Modler (2003). «Transfer of Protein from Milk to Cheese.» Journal of dairy science, 86(2): p. 469-485.

GILLES, J.y.R.C.L. (1985), «The yield of cheese.» New Zealand of Dairy Science and Technology: 20: p. 205-214.

IL-IDF, F.I.D.L. (1993), Cheese yield and Factors Affecting its control. Proceedings of the IDF Seminar. Cork Ireland: p. 540.

Inda Cunningham, Arturo Enrique (2000). Optimización del Rendimiento y Aseguramiento de Inocuidad en quesos. Campestre, México: Organización de los Estados Americanos.

Jimenez-Marquez, S.A., C. Lacroix, and J. Thibault. (2002), «Statistical Data Validation Methods for Large Cheese Plant Database.» Journal of dairy science: 85(9): p. 2081-2097.

Laurene, Fausett (1994). Fundamentals of neural networks. Architectures, algorithms and applications. Prentice-Hall.

Liao, Shu-Hsien (2005). «Expert system methodologies and applications—a decade review from 1995 to 2004.» Expert Systems with Applications: 28 (2005) 93–103.

Lolkema, H. (1993), Factors affecting the yield of cheese., in Factors affecting the yield of cheese. Inter. Dairy Federation: Brussels: D.B Emmonds Editor.

Pécora Rolando P., C.G., Gon Griselda, Dalla Costa César A., Hantis David y Kivatinitz Silvia C. (2008). «Variación anual de la composición química de la leche de vaca de la cuenca lechera de Córdoba, Argentina.» CESIA-CIBSA, M.R.y.J. ZALAZAR.

Vicente Madrid, Antonio (1999), TECNOLOGÍA QUESERA. Editorial AMV.Ediciones Mundi- Prensa.

Zupan, J., y J. Gasteiger (1993). Neural Networks for Chemists. New York: VCH Publishers.

FECHA DE PRESENTACIÓN: 30/06/16 FECHA DE APROBACIÓN: 25/10/16