

**SIMULACIÓN DE LA EVAPORACIÓN DE PELÍCULA DESCENDENTE AL
VACÍO Y CON GAS DE ARRASTRE UTILIZANDO REDES NEURONALES**

CAMILO ANDRÉS ANAYA RUIDÍAZ

PAULA SOLVEY BUENO DELGADO

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOQUÍMICAS
ESCUELA DE INGENIERÍA QUÍMICA
BUCARAMANGA**

2015

**SIMULACIÓN DE LA EVAPORACIÓN DE PELÍCULA DESCENDENTE AL
VACÍO Y CON GAS DE ARRASTRE UTILIZANDO REDES NEURONALES**

CAMILO ANDRÉS ANAYA RUIDÍAZ

PAULA SOLVEY BUENO DELGADO

**Trabajo de grado presentado como requisito para optar por el título de
Ingeniero Químico**

Director:

Prof. CARLOS JESÚS MUVDI NOVA

Ing. Químico, M. Sc., Ph. D.

Codirector:

OMAR ANDRÉS BENAVIDES PRADA

Ing. Químico

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISCOQUÍMICAS
ESCUELA DE INGENIERÍA QUÍMICA
BUCARAMANGA**

2015

TABLA DE CONTENIDO

	Pág.
INTRODUCCIÓN.....	11
1. METODOLOGÍA.....	19
1.1. DISEÑO DE LA ARQUITECTURA DE LA RED.....	19
1.2. IMPLEMENTACIÓN DE LA RED.....	20
1.3. ANÁLISIS DE INFLUENCIA DE LAS VARIABLES.....	24
2. ANÁLISIS DE RESULTADOS.....	25
2.1. ESTUDIO DEL EFECTO DE LOS PARÁMETROS DE DISEÑO DE LA RED EN SU CAPACIDAD PREDICTIVA.....	25
2.2. ENTRENAMIENTO DE LA RED Y SIMULACIÓN DEL PROCESO DE EVAPORACIÓN DE PELÍCULA DESCENDENTE AL VACÍO.....	28
2.3. ANÁLISIS DE INFLUENCIA DE LAS VARIABLES DE ENTRADA EN EL PROCESO DE EVAPORACIÓN DE PELÍCULA DESCENDENTE AL VACÍO.....	32
2.4. ENTRENAMIENTO DE LA RED Y SIMULACIÓN DEL PROCESO DE EVAPORACIÓN DE PELÍCULA DESCENDENTE CON GAS DE ARRASTRE.....	35
2.5. ANÁLISIS DE INFLUENCIA DE LAS VARIABLES DE ENTRADA EN LA EVAPORACIÓN DE PELÍCULA DESCENDENTE CON GAS DE ARRASTRE.....	37
2.6. CÁLCULOS DE COEFICIENTES ENERGÉTICOS Y COMPARACIÓN CON OTROS PROCESOS DE EVAPORACIÓN.....	40
3. CONCLUSIONES.....	43
4. RECOMENDACIONES PARA TRABAJOS FUTUROS.....	44
BIBLIOGRAFÍA.....	45
ANEXOS.....	49

LISTA DE FIGURAS

	Pág.
Figura 1. Esquema de la evaporación de película descendente.....	11
Figura 2. Estructura de una red neuronal <i>Feedforward</i>	15
Figura 3. Diagrama metodológico.....	18
Figura 4. Piloto de evaporación de película descendente.....	21
Figura 5. Diagrama de Pareto estandarizado para MSE.....	25
Figura 6. Regresión lineal entre los datos experimentales de evaporación de película descendente al vacío y los predichos por la red.....	30
Figura 7. Variables del proceso de evaporación de película descendente al vacío obtenidos experimentalmente y los predichos por la red neuronal.....	31
Figura 8. Regresión lineal entre los datos experimentales y los predichos por la red para la evaporación de película con gas de arrastre.....	36
Figura 9. Variables del proceso de evaporación de película descendente obtenidos experimentalmente y los predichos por la red neuronal.....	36
Figura 10. Comparación entre el Consumo Energético Másico (CEM) bajo las mejores condiciones de operación encontradas y otros métodos de evaporación.....	40

LISTA DE TABLAS

	Pág.
Tabla 1. Variables de entrada de evaporación de película descendente al vacío y sus respectivos niveles.....	22
Tabla 2. Variables de entrada de evaporación de película descendente con gas de arrastre y sus respectivos niveles	23
Tabla 3. Valores de los parámetros de diseño que minimizan el error MSE.....	26
Tabla 4. Errores MSE obtenidos con el diseño de red propuesto en la Tabla 1 y cada uno de los métodos de entrenamiento escogidos.....	28
Tabla 5. Resultados de los entrenamientos realizados a la red con los datos de evaporación de película descendente al vacío.....	29
Tabla 6. Factores del diseño experimental del proceso de evaporación de película descendente al vacío y sus respectivos niveles	32
Tabla 7. Análisis de Varianza para el Factor de concentración (F_c), la temperatura de salida (T_s) y el caudal mínimo (Q_{\min}).....	33
Tabla 8. Resultados de los entrenamientos realizados a la red con los datos del proceso de evaporación de película con gas de arrastre.....	35
Tabla 9. Factores del diseño experimental del proceso de evaporación de película descendente con gas de arrastre y sus respectivos niveles.....	37
Tabla10. Análisis de varianza para el factor de concentración (F_c) y el caudal mínimo de operación (Q_{\min}).....	38
Tabla 11. Coeficientes globales de transferencia de calor en evaporadores.....	41

LISTA DE ANEXOS

	Pág.
ANEXO A. Diseño experimental y análisis de influencia de los parámetros de red sobre su capacidad predictiva.....	49
ANEXO B. Datos experimentales del proceso de evaporación de película descendente al vacío.....	52
ANEXO C. Resultados de la simulación de la evaporación de película descendente al vacío con redes neuronales.....	53
ANEXO D. Datos experimentales del proceso de evaporación de película descendente con gas de arrastre.....	54
ANEXO E. Resultados de la simulación de la evaporación de película descendente con gas de arrastre con redes neuronales.....	55
ANEXO F. Mejores condiciones del proceso de evaporación de película descendente al vacío.....	56

RESUMEN

TÍTULO: SIMULACIÓN DE LA EVAPORACIÓN DE PELÍCULA DESCENDENTE AL VACÍO Y CON GAS DE ARRASTRE UTILIZANDO REDES NEURONALES*

AUTORES: CAMILO ANDRÉS ANAYA RUIDÍAZ; PAULA SOLVEY BUENO DELGADO**

PALABRAS CLAVE: REDES NEURONALES, EVAPORACIÓN, SIMULACIÓN, ANÁLISIS DE INFLUENCIA.

Las redes neuronales son una herramienta computacional basada en el cerebro humano, que permiten reconocer patrones entre la información que se le suministra gracias a un proceso de aprendizaje. Debido a esto, su uso en modelamiento de procesos se ha incrementado considerablemente. En el presente estudio se realizó el modelamiento del proceso de evaporación de película descendente al vacío y con gas de arrastre utilizando esta herramienta. Para alcanzar dicho objetivo se diseñó la arquitectura de una red neuronal *Feedforward*, a la cual se le suministraron datos de la evaporación de película descendente al vacío y con gas de arrastre. La mejor estructura de la red neuronal encontrada fue de 2 capas ocultas, 30 neuronas ocultas en cada capa, 60 datos suministrados a la red, 60% de información destinada a entrenamiento y método de entrenamiento de *Levenberg-Maquardt*. Las pruebas se realizaron en base a un diseño experimental factorial 3^3 por duplicado. Para la evaporación de película al vacío se obtuvieron errores promedios de 0,04%; 2,97%; y 8,15% en la predicción de la el factor de concentración, la temperatura de salida y el caudal mínimo de operación, respectivamente. Para la evaporación con gas de arrastre el error en la predicción del factor de concentración fue de 2,91%; mientras que para el caudal mínimo fue de 5,80%. Con el modelo verificado se realizó la simulación del proceso y posterior análisis de influencia de las variables. Se encontró que la concentración de entrada es la variable de mayor influencia en el proceso al vacío, mientras que la velocidad del gas presenta el mayor efecto sobre las variables de salida del proceso con gas de arrastre.

*Trabajo de grado

**Facultad de ingenierías físico-químicas. Escuela de ingeniería química. Director: Carlos Jesús Muvdi Nova, ingeniero químico. Codirector: Omar Andrés Prada Benavides, ingeniero químico.

ABSTRACT

TITLE: SIMULATION OF FALLING FILM EVAPORATION VACUUM AND STRIPPING GAS USING NEURAL NETWORKS*

AUTHORS: CAMILO ANDRES ANAYA RUIDIAZ; PAULA SOLVEY BUENO DELGADO**

KEYWORDS: NEURAL NETWORKS, EVAPORATION, SIMULATION, ANALYSIS OF INFLUENCE

Neural networks are a computational tool based on the human brain, which can recognize patterns between information that is supplied through a learning process. Because of this, its use in process modeling has increased considerably. In the present study the modeling of falling film evaporation at vacuum conditions and with stripping gas was performed using this tool. To achieve this objective the architecture of a Feedforward neural network was designed, which was supplied with falling film evaporation data under vacuum conditions and with stripping gas. The best structure of the neural network found was 2 hidden layers, 30 hidden neurons in each layer, 60 data supplied to the network, 60% of information for training and training method Levenberg-Maquardt. The tests were performed based on a 3^3 factorial experimental design with duplicates. For vacuum film evaporation average errors of 0.83%; 0.17% y 5.24% were obtained in the prediction of the concentration factor, the output temperature and the minimum operating flow rate, respectively. Prediction error for the concentration factor in falling film evaporation with stripping gas was 2.91%; while for the minimum flow was 5.80%. With the verified model a simulation of the processes was carried out, and a subsequent influence analysis of the variables involved. It was found that the inlet concentration is the most influential variable in the vacuum process, while the gas velocity has the greatest effect on the output variables of the process with stripping gas.

*Degree work


**Faculty of physical-chemical engineering. School of chemical engineering. Director: Carlos Jesús Muvdi Nova, chemical engineer. Codirector: Omar Andrés Prada Benavides, chemical engineer.

INTRODUCCIÓN

Tener una comprensión adecuada respecto a los diferentes fenómenos que pueden ocurrir en un proceso (generalmente complejo) permite que se avance en materia de diseño, operación y optimización de estos. Dicha asimilación se ha llevado a cabo mediante varias técnicas teóricas y empíricas, como por ejemplo el modelamiento. El uso de ecuaciones de conservación y correlaciones son algunos de los procedimientos usados con este propósito. Sin embargo, existen procesos de alta complejidad, como los de la industria de alimentos, en los cuales se hace aún más difícil el uso de ecuaciones (teóricas) para describirlos; afectando la veracidad en los resultados obtenidos con ellas.

En el caso de la industria de alimentos, el estudio fenomenológico de sus procesos es relativamente nuevo y tiene cierta dificultad debido a que en ella se manejan materias primas complejas (Chen & Jebson, 1997). Para el presente proyecto se plantea el estudio de la evaporación de película descendente. Esta operación unitaria, de gran interés para la industria de alimentos (reducción de costos de consumo energético y tamaño de los equipos) (Li *et al.*, 2011), es un ejemplo de un proceso (de alta complejidad) donde se involucra todos los fenómenos de transferencia de forma acoplada. A continuación se presenta un esquema de este proceso (ver Figura 1).

Figura 1. Esquema de la evaporación de película descendente. Fuente: Autores.



Esta figura muestra una película líquida de grosor δ , temperatura T_L y concentración C_A fluyendo a lo largo de una pared vertical con temperatura T_p (debido a la acción de la gravedad) (Brotherton, 2002). El grosor de la película disminuye a medida que desciende mientras la concentración aumenta debido a la evaporación (Assad & Lampinen, 2002). Este proceso suele llevarse a cabo en condiciones de vacío, ya que se obtienen bajas temperaturas de ebullición de la película. Esto contribuye a incrementar la masa evaporada a temperaturas no tan altas, disminuyendo así los costos energéticos (Chen & Jebson, 1997). No obstante, se han contemplado otras posibilidades para el proceso, como el uso de una corriente de gas que entre en contacto con la película (gas de arrastre) (Feddaoui *et al.*, 2006). El contacto genera una transferencia de masa (agua) desde la película hacia el gas, produciéndose un aumento en la concentración de la película.

Sobre este tema se han llevado a cabo diferentes estudios. Muchos de ellos predicen satisfactoriamente las variables de un proceso; sin embargo, su veracidad está sujeta a las suposiciones realizadas. Por ejemplo, Assad & Lampinen (2008), Brotherton (2002), Batistella & Maciel (1996) y Pacheco & Frioni (2004) realizaron el modelamiento de la evaporación de agua, mezclas de etanol-agua, ftalato de dibutilo - sebacato de dibutilo y soluciones de sacarosa, respectivamente. Para esto se basaron en ecuaciones de conservación, considerando flujo en régimen laminar, propiedades físico-químicas constantes, condiciones de equilibrio de fases y estado estable; además, los parámetros y propiedades físicoquímicas (como viscosidad y densidad) se hallaron mediante ecuaciones teóricas y empíricas (Pacheco & Frioni, 2004). Feddaoui *et al.* (2006) también realizaron balances para evaporación de agua en condiciones de flujo turbulento, asumiendo flujo incompresible y ausencia de disipación viscosa, radiación y fenómenos de transporte en dirección axial.

Como resultado se obtiene en cada caso un modelo que describe la fenomenología del proceso con errores pequeños, cercanos al 3% en sus predicciones de fracción de líquido evaporado (Brotherton, 2002). Se demostró además que la fracción de evaporación aumenta con un aumento en la temperatura de entrada o en la pared del evaporador (Feddaoui *et al.*, 2006). Sin embargo, para lograr esta confiabilidad en los datos se hizo necesario el uso de sistemas de 10 o más ecuaciones (Feddaoui *et al.*, 2006) (Batistella & Maciel, 1996). Entre las variables trabajadas se encuentran la temperatura de película y pared, la velocidad y el esfuerzo de cizalla en la interfase líquido-sólido ocasionado por la fricción. Esta cantidad de ecuaciones hace que se dificulte su comprensión y limite el diseño del proceso.


Otra alternativa de modelamiento es el desarrollo de correlaciones a través del análisis matemático de datos experimentales. Chen & Jebson (1997) y Adib *et al.* (2009) realizaron estudios sobre la evaporación de película descendente de soluciones de azúcares utilizando esta metodología. Analizaron el efecto producido en el coeficiente de transferencia de calor debido a cambios en la composición, temperatura de la alimentación, así como las temperaturas de la película del líquido y del vapor producido. Se encontró que una diferencia de temperatura (entre la película y la pared) superior a 5°C da lugar a la formación de burbujas; además, a medida que esta variable aumenta disminuye el valor de los coeficientes de transferencia de masa y energía. Se desarrolló una expresión matemática mediante regresión lineal que relaciona la fracción de sacarosa con los coeficientes. No obstante, se hicieron necesarias ecuaciones para los números adimensionales Reynolds y Prandtl, lo que restringe la aplicación de resultados a la confiabilidad de dichas expresiones (Chen & Jebson, 1997).

Debido a estas dificultades se ha planteado el uso de nuevas formas de modelamiento y simulación. Una opción que ha probado su eficacia en la

simulación de procesos complejos es el uso de redes neuronales (modelamiento empírico). Esta herramienta de modelamiento surge como resultado del desarrollo computacional alcanzado en la actualidad. Su funcionamiento se basa en los sistemas biológicos, y se caracteriza por su capacidad de “aprender” de los datos que le suministran (Basheer & Hajmeer, 2000). Su estructura consiste en un grupo de neuronas conectadas entre sí, formando una red capaz de procesar gran cantidad de información (Hines & Carnevale, 2004). La presencia de funciones de transferencia entre neuronas permite simular relaciones no lineales entre las variables (Fullana *et al.*, 2000). Además, no hay restricción en el número de variables de entrada y salida. Su proceso de “aprendizaje” lo lleva a cabo mediante un entrenamiento, en el cual se le suministran datos de entrada y salida. Dicho entrenamiento consiste en un proceso iterativo en el cual la red modifica los parámetros presentes en su estructura (cargas y valores umbral). Esto con el propósito de hacer que sus valores de salida coincidan con los datos suministrados. Durante este proceso se realiza una serie de evaluaciones para verificar la capacidad predictiva que adquiere la red. Es por esto que la red divide la información que se suministra en tres partes: información para entrenamiento, validación y *test*. La información destinada a entrenamiento, como su nombre lo indica, es la utilizada para entrenar la red y modificar sus parámetros. Por otro lado, el proceso de validación se encarga de corroborar el proceso de aprendizaje de la red. Cuando el error de validación aumenta durante seis iteraciones seguidas en un entrenamiento, el proceso de entrenamiento se detiene (Hagan *et al.*, 1996). Por su parte, la información restante (para *test*) proporciona datos independientes que la red no conoce, para evaluar la capacidad predictiva de ésta. Para que este proceso se lleve a cabo de manera satisfactoria los parámetros de diseño de la red deben seleccionarse adecuadamente. Los parámetros de mayor influencia en la capacidad predictiva final de la red son su arquitectura (número de capas y neuronas por capa oculta), método de entrenamiento (Menéndes & Llano del Bosque, 2010), cantidad de datos suministrados (Machón *et al.*, 2007) y porcentaje de información destinada a entrenamiento, validación y *test* (Hagan *et al.*, 1996).

En la Figura 2 se muestra un esquema de la estructura de una red neuronal *Feedforward* (que será el modelo utilizado en este trabajo). La principal característica de esta red es que la información fluye en un sentido (hacia adelante), es decir, no hay recirculación de información (Hagan *et al.*, 1996). En la figura también puede apreciarse la presencia de las capas de entrada, ocultas y de salida. Su función es recibir las variables de entrada, transformarlas en información de salida y presentar los resultados, respectivamente (Fullana *et al.*, 2000).

Figura 2. Estructura de una red neuronal *Feedforward*. Fuente: Autores.



Esta herramienta ha sido aplicada en diversos campos con gran éxito. Gerstberger & Rentrop (2013) usaron redes neuronales entrenadas mediante retropropagación (método que consiste en la modificación de cargas y valores umbral de la red mediante procesos iterativos) a partir de datos obtenidos mediante ecuaciones diferenciales discretizadas por el método de Euler, como la ecuación de Van der Pol. Por otro lado, Jeong *et al.* (2001) también utilizaron la retropropagación como estrategia de entrenamiento de la red para la simulación de la actividad del fitoplancton en un río. En este estudio, la red fue entrenada con datos medioambientales recogidos en un período de 20 a 30 años, usando la concentración de clorofila como variable de salida. Se realizaron de 15 000 a 18 000 iteraciones en aproximadamente 3 min (Gerstberger & Rentrop, 2013). Además, se consiguieron errores del orden de 0,0015 (Jeong *et al.*, 2001) en la concentración de clorofila en el río. Como se puede evidenciar, el uso de esta técnica permite dar resultados confiables y rápidos a procesos que presentan difícil modelamiento.

Debido a esto, son cada vez más los estudios científicos que aplican la simulación por redes neuronales para el análisis de procesos. Fullana *et al.* (2000) simularon el proceso de extracción de *Nigella Sativa* con CO₂ supercrítico, complementando la simulación con un balance de aceite en el sistema; mientras Machón *et al.* (2007) simularon la nitrificación de aguas residuales provenientes de la producción de acero. Las variables de salida fueron la solubilidad del aceite en el dióxido de carbono y el flujo de solvente, respectivamente. Para el primer trabajo la red fue entrenada por retropropagación y en el segundo, se utilizó el algoritmo de *Levenberg-Marquardt*. En ambos casos se obtuvieron datos con errores menores al 10%.

Las redes neuronales también han sido utilizadas como controladores de procesos. Dirion *et al.* (2002) usaron una red neuronal para controlar la temperatura de operación de un reactor. Para esto, introdujeron como variables de entrada el valor de *setpoint* de la temperatura, la variable controlada y la manipulada (apertura de la válvula de líquido de enfriamiento). La variable de salida fue la apertura de válvula requerida para mantener la temperatura en su *setpoint*. Las temperaturas observadas fueron comparadas con las obtenidas con un controlador GPC-RM (*Generalized Predictive Control with double model reference*), comprobando la precisión del controlador virtual.

Debido a la confiabilidad en sus resultados, la aplicación de redes neuronales en el estudio de procesos industriales aumenta rápidamente. Un ejemplo de esto son los casos expuestos por Lennox *et al.* (2001), en los cuales se realizó modelamiento por redes neuronales. Dos de ellos son la vitrificación (encapsulamiento en vidrio de residuos líquidos utilizando calor) en la empresa British Nuclear Fuels Ltd. y la filtración rápida por gravedad en la empresa Thames Water. Las variables de respuesta consideradas fueron la temperatura del recipiente y la turbidez del agua filtrada, respectivamente.

Por tal motivo, el objetivo del presente trabajo es el modelamiento del proceso de evaporación de película descendente al vacío y con gas de arrastre mediante redes neuronales. Esta herramienta no ha sido utilizada para el estudio de este tipo de operación unitaria. Para cumplir con este objetivo se definió la estructura de la red (que puede modificarse de ser necesario) y se realizaron experimentos de evaporación, cuyos resultados fueron usados en la etapa de entrenamiento. Posteriormente, se realizó la simulación con la herramienta computacional validada, con el propósito de analizar la influencia de las variables de entrada en el proceso. Este trabajo hace parte del proyecto titulado: Aumento de la productividad de concentrados de jarabe de glucosa obtenidos a partir de hidrolizados de almidón de yuca por métodos no convencionales con código 1102-5022-7720 COLCIENCIAS – UIS – PROMITEC SANTANDER S.A.S.

FASE 1. Diseño de la arquitectura de la red

En esta primera fase se encontró el mejor diseño de la red basándose en el mínimo error obtenido. Para esto se utilizaron datos experimentales de un proceso de destilación con membranas como información suministrada para el entrenamiento (Benavides & Guevara, 2010). Las variables de entrada de este proceso fueron: presión, temperatura, número de Reynolds, concentración, diámetro de poro, espesor y porosidad. Las variables de salida fueron: flux de agua, flux de etanol y fracción másica. Estas variables determinarán el número de neuronas de capas de entrada y salida de la red.

Para este trabajo se eligió una red *feedforward* con funciones de transferencia *logsig* y *purelin* en las capas ocultas y de salida, respectivamente. Esta elección se basó en los buenos resultados obtenidos con esta arquitectura en trabajos consultados (Machón *et al.*, 2007). Las redes fueron creadas y entrenadas con el *software* Matlab 7.0.4. Los parámetros de diseño a los que se realizó el estudio fueron: la arquitectura de red (# Neuronas y # Capas ocultas), el método de entrenamiento, la cantidad de datos suministrados y el porcentaje de estos datos que se usan para entrenamiento, validación y *test*. Para analizar la influencia de estos factores en la capacidad predictiva de la red, se realizó un diseño experimental factorial 3^4 por triplicado (ver Anexo 1). Se usó como criterio de selección el error al cuadrado promedio MSE (Velásquez *et al.*, 2006). Inicialmente se trabajó con el método de entrenamiento *Levenberg-Marquardt* (sugerido por Matlab). Los valores considerados para cada parámetro fueron los siguientes:

- # Neuronas por capa oculta (10, 30, 50)
- # Capas ocultas (1, 2, 3)
- # Experimentos (20, 60, 100)
- % Información destinada a entrenamiento. 30, 60, 90 % (porcentajes iguales de información para validación y prueba).


Se realizó el entrenamiento de la red para cada diseño y los resultados obtenidos fueron analizados estadísticamente usando *StatGraphics Centurion XVI.II*® (versión de prueba). De dicho análisis se obtuvieron los factores de mayor influencia y el diseño óptimo de red. Con estos parámetros se evaluaron los siguientes métodos de entrenamiento: *variable training rate*, *resilient backpropagation*, *Powell-Beale restarts*, *scaled conjugated gradient*, *one-step secant algorithm*, *Levenberg-Maquardt algorithm*. Los criterios de selección de dichos métodos fueron la rapidez de convergencia, capacidad de almacenamiento requerida para cada iteración, capacidad de identificar mínimos globales y conveniencia de un método para cierta estructura de red.

Al finalizar esta etapa, se obtuvo la estructura de la red y los parámetros de entrenamiento que fueron usados en la siguiente fase del proyecto.

FASE 2: Implementación de la red

En esta fase se llevaron a cabo los experimentos con el evaporador de película descendente al vacío y con gas de arrastre (Ver figura 4), diseñado por Solano & Muñoz (2014) y el entrenamiento de la red con los datos obtenidos.

Figura 4. Piloto de evaporación de película descendente. Fuente: Muñoz & Solano, (2014)



El piloto presentado en la figura anterior, fue diseñado para trabajar la evaporación de película descendente al vacío como con gas de arrastre. Para la primera técnica se cuenta con una bomba de vacío **(9)**, la cual está encargada de disminuir la presión en el sistema. Debido a esta disminución, la solución que se encuentra en el tanque de alimentación **(3)** es succionada, ingresando al sistema evaporador **(4)**. Después de su ingreso, la solución desciende a través del tubo de acero, el cual contiene (internamente) una resistencia eléctrica encargada de proporcionar la energía para el proceso de evaporación. El líquido concentrado y el vapor generado pasan al ciclón **(5)**, en donde son separados. Luego, el concentrado se recupera en el tanque **(7)**, mientras que el vapor pasa a un condensador, para ser recuperado en el tanque **(8)**. Para la configuración con gas de arrastre, al igual que al vacío, la alimentación entra por la parte superior, esta vez impulsada por la bomba de alimentación **(1)**. En este caso, el medio de calentamiento para la evaporación es un flujo de aire. Este último es tomado del ambiente utilizando un ventilador **(10)** que lo aspira a través del conducto de succión **(12)**. El aire pasa primero por un sistema de calentamiento **(11)** antes de

entrar al evaporador (parte superior derecha). Posteriormente, el aire calienta la película de líquido generando vapor. El líquido concentrado y la mezcla aire-vapor pasa al ciclón para ser separados. Se recupera el concentrado y el aire es enfriado en el condensador antes de ser retirado al ambiente. Las soluciones para cada uno de estos experimentos, se prepararon con los jarabes de glucosa facilitados por Promitec Santander S.A.S.

Además de los datos experimentales, se requirió la red estructurada en la fase anterior. Las pruebas se realizaron con base a un diseño experimental factorial 3^3 por duplicado para ambas técnicas. Esto sirvió para analizar la capacidad del modelo en la predicción de variables de proceso. Dicho análisis se realizó a partir de los valores obtenidos de MSE (Velásquez, 2006). El *software* utilizado para la simulación fue Matlab 7.4 (R2007a).

En las tablas 1 y 2 se presentan las variables de entrada que se tuvieron en cuenta en los diseños experimentales para la evaporación al vacío y con gas de arrastre, respetivamente. Los niveles de cada variable mostrados en dichas tablas, se establecieron teniendo como criterio la seguridad del proceso y la capacidad de medición de los sensores del piloto.

Tabla 1. Variables de entrada de evaporación de película descendente al vacío y sus respectivos niveles. Fuente: Autores.

Variable	Niveles
Concentración de entrada (Ce) [°Brix]	10 - 20 - 40
Presión de vacío (Pv) [mbar]	200 - 250 - 300
Temperatura de pared (Tp)[°C]	80 - 85 - 90

Tabla 2. Variables de entrada de evaporación de película descendente con gas de arrastre y sus respectivos niveles. Fuente: Autores.

Variable	Niveles
Concentración de entrada (Ce) [°Brix]	10 - 20 - 40
Velocidad del aire (Vg) [m/s]	10 – 12,5 – 14,5
Temperatura del aire (Tg) [°C]	85 - 95 - 105

Además de esto, en la evaporación del película descendente al vacío, la temperatura de alimentación fue fijada algunos grados (2-5°C) por debajo de la temperatura de ebullición de la solución a la presión de trabajo, para evitar la ebullición de ésta antes de su ingreso al evaporador. Para la evaporación de película descendente con gas de arrastre, la temperatura del alimento fue de 80°C (temperatura de hidrólisis) para todas las pruebas. El mismo valor tomó la temperatura del tubo, para evitar la transferencia de calor hacia el mismo durante el tiempo de duración de las pruebas (20 min para la evaporación al vacío, 15 min para el proceso con gas de arrastre). Esto garantiza que sólo el aire contribuya a la evaporación de la película. Los datos experimentales se presentan en los Anexos 2 y 4.

Por su parte, las variables de salida en la evaporación de película al vacío fueron el factor de concentración, la temperatura del concentrado y el caudal mínimo de operación (hallado mediante un balance másico de glucosa). Para el proceso con gas de arrastre, las variables de salida fueron el factor de concentración y el caudal mínimo. De acuerdo a esto (variables de entrada y de salida), para el caso del proceso de evaporación al vacío hubo 4 neuronas en la capa de entrada y 3 neuronas en la capa de salida. En el caso del proceso con gas de arrastre hubo 3 neuronas en la capa de entrada y 2 en la capa de salida.

Al final de esta fase se obtuvo el modelo (un “evaporador de película virtual”) y los rangos de validación de éste.

FASE 3: Análisis de influencia de las variables

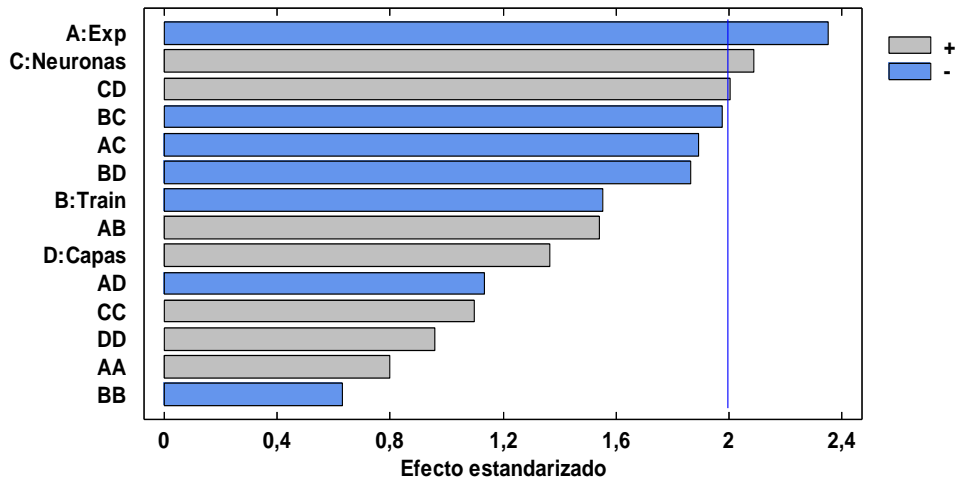
El objetivo de esta última etapa fue entender y explicar el proceso de evaporación de película descendente. Para ello se trabajó considerando diseños experimentales del tipo factorial multinivel dentro de los rangos de validación del modelo, obtenidos en la Fase 2. Para la configuración en vacío, el diseño consistió en 7 niveles para concentración de entrada y 6 niveles para Temperatura de pared y Presión de vacío (252 experimentos). Para el caso de gas de arrastre, el diseño experimental estuvo conformado por 7 niveles para la Concentración de entrada, 10 niveles para la Velocidad del aire y 5 niveles para la Temperatura del aire a la entrada (350 experimentos). A partir de estos diseños se determinó el efecto que tiene cada una de las variables de entrada sobre las variables de salida y las mejores condiciones de proceso. Es importante señalar que para el caso de la temperatura de entrada en la configuración al vacío, ésta se fijó 5°C por debajo de la temperatura de ebullición a la presión de trabajo, considerando lo realizado en la Fase 2. El análisis se realizó utilizando *Statgraphics Centurion XVI.I*® (versión de prueba). Los datos que se usaron en este *software* fueron los resultados de la simulación por redes neuronales para el conjunto de datos generados a partir de los diseños experimentales.

ANÁLISIS DE RESULTADOS

Estudio del efecto de los parámetros de diseño de la red en su capacidad predictiva.

En esta fase del proyecto se realizó un diseño experimental factorial 3^4 por triplicado (ver Anexo 1) que analizó de los parámetros de diseño de la red en su capacidad predictiva. Las variables tenidas en cuenta fueron el # Capas ocultas de la red, el # Neuronas en dichas capas, el % Información de entrenamiento y el # Experimentos. Como variable de salida se escogió el Error MSE (función de desempeño obtenida durante el entrenamiento). El análisis estadístico se llevó a cabo usando los resultados obtenidos por Benavides & Guevara (2010). Los resultados son resumidos en el Diagrama de Pareto de la Figura 5.

Figura 5. Diagrama de Pareto estandarizado para MSE (error de entrenamiento) obtenido con *Statgraphics Centurion XVI.I®* (versión de prueba). Fuente: Autores.



De esta figura se puede observar que el # Experimentos suministrados a la red fue la variable más significativa para el modelamiento por redes neuronales. Le sigue en significancia el # Neuronas. El color de las barras muestra que un aumento en el # Experimentos (o una disminución en el # Neuronas) produce una disminución en el error MSE. Esto se debe a que un número mayor de datos genera mejor entrenamiento y mayor aprendizaje (Machón *et al.*, 2007). Por otro lado, el aumento del # Neuronas en la capa oculta podría generar sobreaprendizaje, lo que afecta la capacidad de generalización de la red (Piotrowski *et al.*, 2013).

Estos resultados fueron afines con varias investigaciones científicas, en donde se modificaron el número de experimentos y neuronas para minimizar el error de entrenamiento. Machón *et al.* (2007) obtuvieron resultados similares, logrando reducir el error al usar una red de ocho neuronas en la capa oculta y al aumentar los datos suministrados hasta treinta y cinco. Otro ejemplo es el trabajo reportado por Fullana *et al.* (2000), quienes realizaron el entrenamiento de redes variando el número de neuronas en la capa oculta. El número óptimo de neuronas encontrado en este caso fue de seis. Sin embargo, debe tenerse en cuenta que en ambos estudios se trabajó con una sola variable de salida, lo que disminuye el requerimiento de neuronas y conexiones entre ellas. En lo referente a la influencia del número de capas ocultas y el % Entrenamiento en la capacidad predictiva de la red, sus efectos no fueron significativos.

Los valores de cada parámetro que minimizaron el error MSE en los intervalos especificados se obtuvieron con ayuda del programa estadístico. Los resultados se muestran en la siguiente tabla.

Tabla 3. Valores de los parámetros de diseño que minimizan el error MSE. Fuente: Autores.

Factor	Experimentos	Entrenamiento	Neuronas por capa oculta	Capas
Valor óptimo	60	60%	30	2

De esta tabla se evidencia que el número de experimentos y neuronas en las capas ocultas fue ligeramente mayor al requerido en algunos trabajos consultados (Machón *et al.*, 2007) (Fullana *et al.*, 2000). Debe tenerse en cuenta que el rango para el número de neuronas por capa oculta, en el diseño experimental planteado, no consideró valores menores a 10. Esto se debe a que los trabajos consultados usaron un menor número de variables de entrada y salida, lo que disminuye el número de conexiones en la red. Por otro lado, el % Entrenamiento óptimo fue el sugerido por Matlab para entrenar la red (Hagan *et al.*, 1996). El número óptimo de capas ocultas fue de dos. Este resultado refleja el aumento requerido en el número de conexiones de la red al aumentar las variables que se manejan. Cabe resaltar que, si bien el # Capas ocultas no tuvo influencia significativa, un cambio simultáneo de esta variable y el número de neuronas si presenta un efecto significativo positivo (Figura 4). Este resultado demuestra que al incrementarse el número de variables que maneja la red, su arquitectura debe contar con mayor número de conexiones.

Dicho aumento en las conexiones ha sido evidenciado en investigaciones anteriores con resultados satisfactorios. Por ejemplo, Menéndez de Llano & Bosque (2010) utilizaron una red neuronal de dos capas ocultas en su investigación (influencia de los parámetros de red en su capacidad predictiva). Se analizó la influencia del # Neuronas (pruebas con 10, 20, 30, 40 y 50 neuronas por capa) en el entrenamiento. Los datos usados para entrenar la red se obtuvieron de un proceso de colisión electrón-positrón. La red con mejor

desempeño fue la de 50 neuronas por capa oculta. Esto se reflejó en una eficiente actualización de datos durante todo el proceso de entrenamiento. Este resultado demuestra que el número de capas y/o neuronas ocultas debe ser aumentado en casos donde la cantidad de información manejada por la red así lo requiera.

Otro parámetro de gran importancia en el diseño de una red es el método de entrenamiento usado (Hagan *et al.*, 1996) (Menéndez de Llano & Bosque, 2010) (Zhang & Subbarayan, 2002). Su adecuada elección determina tiempos cortos de entrenamiento y simulación, alta convergencia, entre otros factores (Hagan *et al.*, 1996). Para dicha selección, se evaluaron distintos métodos de entrenamiento con el diseño de red propuesto anteriormente (ver Tabla 3). Estos métodos fueron escogidos en base a un análisis previo. Los resultados se muestran en la Tabla 4. En esta tabla se observa que la red entrenada con el algoritmo de *Levenberg-Maquardt* presentó el menor error durante el entrenamiento. Con base a estos resultados se decidió trabajar con dicho algoritmo para entrenar la red en las siguientes fases del proyecto.

Tabla 4. Errores MSE obtenidos con el diseño de red propuesto en la Tabla 3 y cada uno de los métodos de entrenamiento escogidos. Fuente: Autores.

Métodos de entrenamiento	MSE
<i>Levenberg-Maquardt algorithm (trainlm)</i>	2,86E-03
<i>Variable training rate (traingdx)</i>	5,64E-02
<i>Resilient back propagation (trainrp)</i>	5,44E-03
<i>Powell-Beale restarts (traincgb)</i>	1,26E-02
<i>Scaled conjugated gradient (trainscg)</i>	7,52E-02
<i>One step secant algorithm (trainoss)</i>	6,41E-02

Entrenamiento de la red y simulación del proceso de evaporación de película descendente al vacío.

Luego de obtener el diseño óptimo de la red, se realizó el entrenamiento de ésta para la evaporación de película descendente al vacío. Para esto, se suministraron los datos experimentales obtenidos para este proceso (ver Anexo 2). La eficacia del proceso de entrenamiento se evaluó analizando el error resultante (error MSE). Cabe resaltar que el proceso de entrenamiento termina cuando el error de validación aumenta durante seis iteraciones seguidas. Debe tenerse en cuenta que los datos destinados a entrenamiento, *test* y validación son escogidos aleatoriamente, por lo que el resultado de cada entrenamiento es diferente. Esto quiere decir que el proceso de entrenamiento puede llevarse a cabo varias veces, en caso de que los resultados de simulación obtenidos no sean los requeridos.


En este caso, el proceso de entrenamiento de la red fue llevado a cabo 7 veces, debido a que el error de predicción resultante era mayor que el reportado en trabajos como el de Brotherton (Brotherton, 2002). El menor error MSE fue de 0,0006; este valor se obtuvo en la primera iteración del último entrenamiento (séptimo), como puede observarse en la Tabla 5. Este resultado se debe a que los valores de las cargas y los valores predispuestos no fueron reiniciados después de cada entrenamiento. Por lo tanto, cada vez que la red inicia un entrenamiento lo hace con una capacidad predictiva mayor. Esto a su vez causa que dicho entrenamiento requiera de menos iteraciones para alcanzar valores de error específicos (hasta un mínimo de 7 pues el criterio de parada es que el error de validación suba 6 iteraciones seguidas). En la Tabla 5 se muestra el comportamiento del error MSE en el último entrenamiento.

Tabla 5. Resultados de los entrenamientos realizados a la red con los datos de evaporación de película descendente al vacío. Fuente: Autores.

Entrenamiento	Iteraciones	Error MSE
1	13	0,1178
2	9	0,1014
3	8	0,0284
4	7	0,0137
5	7	0,0053
6	7	0,0007
7	7	0,0006

Para realizar la validación del entrenamiento se lleva a cabo una regresión lineal con los valores de salida de la red y los datos experimentales. Esta opción brinda una medida (indirecta) de la capacidad predictiva de la red. Para redes con alta capacidad predictiva, la función resultante de la regresión debe ser la función identidad (recta $y=x$) con un coeficiente R^2 lo más cercano a uno. En la Figura 6 se muestran los resultados del proceso de validación.

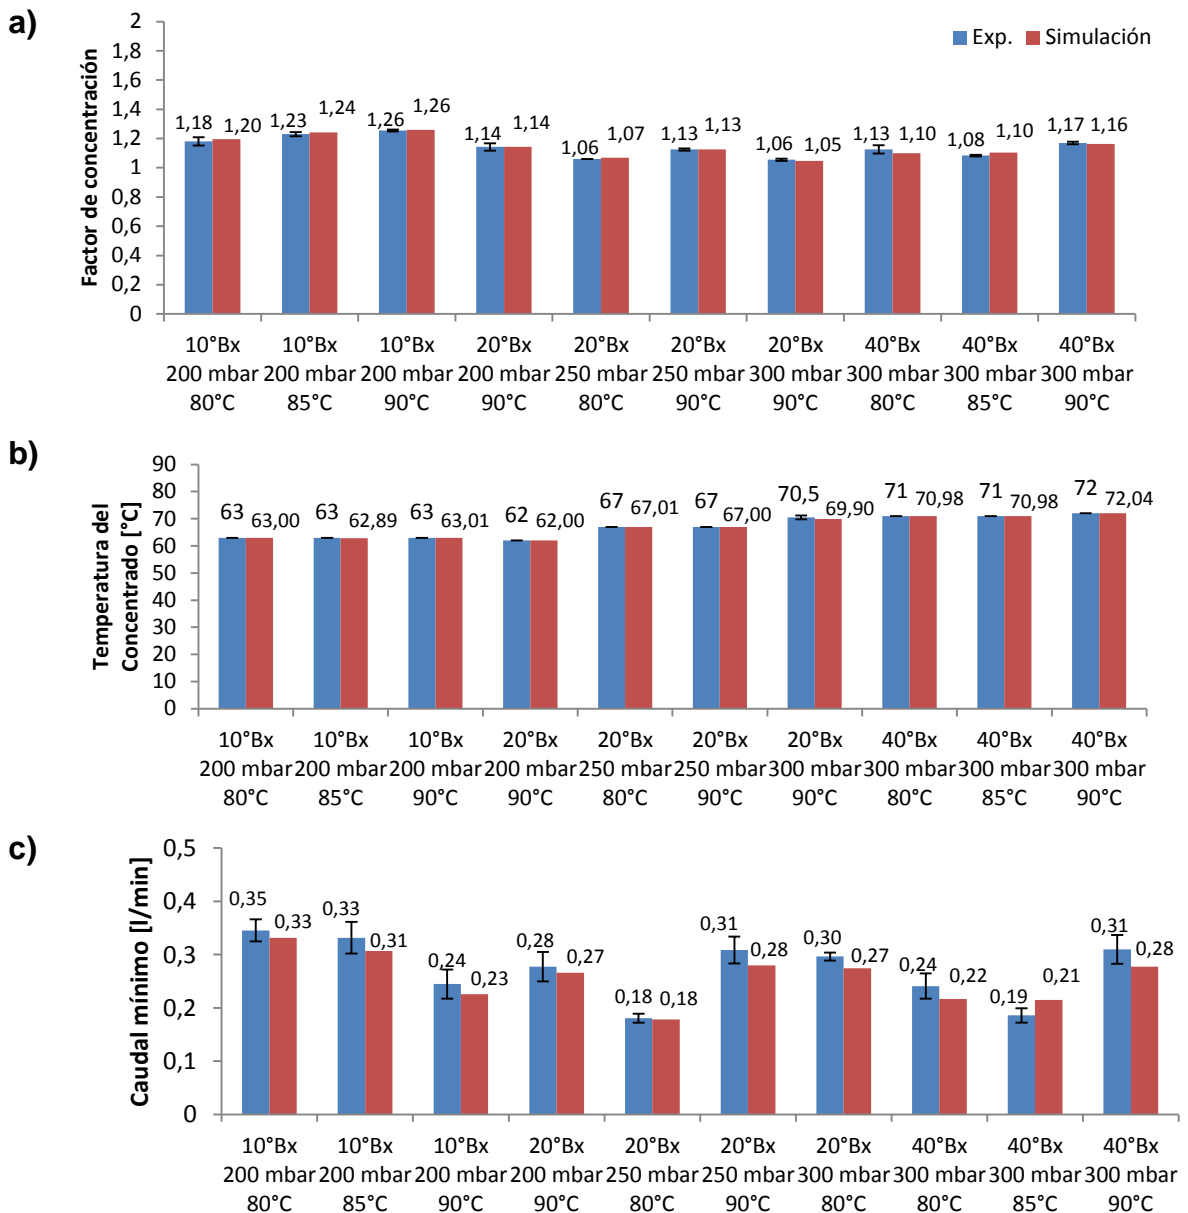
Figura 6. Regresión lineal entre los datos experimentales de evaporación de película descendente al vacío y los predichos por la red. Fuente: Autores.



Puede observarse que el coeficiente R^2 fue muy cercano a 1 (0,9999). Este valor es mayor al obtenido en los trabajos de Adib *et al.* (2009) que es de 0,89, lo que muestra la efectividad del modelamiento por redes neuronales de la evaporación

de película al vacío. Posteriormente, se realizó la simulación con los datos de entrada alimentados en el entrenamiento, con el objetivo de validar los resultados generados por la red (Ver Anexo 3). En la Figura 7 se muestran comparaciones entre algunos datos experimentales y los simulados.

Figura 7. Variables del proceso de evaporación de película descendente al vacío obtenidos experimentalmente y los predichos por la red. a) Factor de concentración, b) Temperatura del concentrado y c) Caudal mínimo requerido. Fuente: Autores.



Se obtuvieron errores promedio de 0,83%; 0,17% y 5,24% en la predicción del factor de concentración, la temperatura de salida del concentrado y el caudal mínimo (requerido para la formación de la película), respectivamente. Los errores en la temperatura de salida del concentrado fueron menores a los obtenidos por Barghava *et al.* (2008) en su estudio (1,8%). Por otro lado, El-Genk & Saber (2000) obtuvieron errores de hasta 20% en la predicción del grosor mínimo de película. Estos errores son mayores a los resultantes de la simulación con redes neuronales para el caudal mínimo. Además, el modelamiento realizado en estos dos casos reportados requirió información acerca del proceso y las sustancias, lo que lo convierte en una tarea compleja.

Análisis de influencia de las variables de entrada en el proceso de evaporación de película descendente al vacío.

Los errores de predicción obtenidos por parte del modelo para la evaporación de película descendente al vacío fueron aceptables en los rangos usados para cada variable. A partir de estos rangos y del diseño experimental planteado se llevó a cabo el proceso de simulación y posterior análisis de influencia de las variables de proceso. Los niveles que tomaron las variables se muestran en la Tabla 6.

Tabla 6. Factores del diseño experimental del proceso de evaporación de película descendente y sus respectivos niveles. Fuente: Autores.

Variable	Concentración de entrada (Ce) [°Brix]	Presión de vacío (Pv) [mbar]	Temperatura de pared (Tp) [°C]
Niveles	10, 15, 20, 25, 30, 35, 40	100, 120, 140, 160, 180, 200	80, 82, 84, 86, 88, 90

Las temperaturas de entrada fueron fijadas 5°C por debajo del punto de ebullición a la presión de trabajo para evitar la ebullición de la solución antes de su ingreso al evaporador.

La Tabla 7 muestra los resultados del análisis estadístico realizado a los datos obtenidos con la simulación. En dicho análisis se determinó la influencia de las variables de entrada en cada una de las variables de salida.

Tabla 7. Análisis de Varianza para el Factor de concentración (Fc), la temperatura de salida (Ts) y el caudal mínimo (Qmín). Fuente: Autores.

Variable*	Fc		Ts		Qmin	
	Efecto	Valor P	Efecto	Valor P	Efecto	Valor P
Ce	-0,1348	0,0000	-0,0237	0,9182	-0,2826	0,0000
Pv	0,0040	0,6869	8,4326	0,0000	-0,0146	0,2261
Tp	0,0475	0,0000	1,1826	0,0000	0,1017	0,0000

*Ce: Concentración de entrada; Pv: Presión de vacío; Tp: Temperatura de la pared.

Los valores del parámetro estadístico P permiten identificar las variables significativas en el proceso ($P < 0,05$). Por su parte, el valor del efecto indica el cambio en la variable de salida por unidad de cambio de una variable de entrada. De acuerdo a esto, la variable de mayor influencia en el factor de concentración y el caudal mínimo fue la concentración de entrada, seguida por la temperatura de pared. Puede concluirse que una disminución de una unidad en la concentración de entrada provoca un aumento de 0,1348 en el factor de concentración. Esto se debe a que la viscosidad disminuye a menores concentraciones, lo que genera un aumento en la transferencia de energía (Chen & Jebson, 1997). Dicho aumento favorece la evaporación y, a su vez, la concentración a la salida. Por otro lado, un incremento en la temperatura de pared en una unidad genera que el factor de concentración aumente en 0,0475 su valor. Esto se debe a que un aumento de la temperatura en la pared del intercambiador mejora la transferencia de calor, generando un aumento de la presión de vapor de la solución. Esto hace que aumente la evaporación del agua de la solución, y con ello, el factor de concentración. La presión de vacío no tuvo un efecto significativo.

Por otra parte, la variable con el mayor efecto en la temperatura de salida fue la presión de vacío. La temperatura de la pared presentó la segunda mayor influencia (ver efectos, Tabla 7). La temperatura de salida muestra un incremento en su valor ante un aumento en la presión del sistema o en la temperatura de pared. Esto se debe a que la temperatura de ebullición de la solución (que es la temperatura de salida) aumenta con la presión del sistema. Maximo *et al.* (2010) encontraron en su estudio que un aumento de 200 mbar en la presión del sistema ocasiona que la temperatura de ebullición aumente 16°C aprox. De otra parte, un aumento en la temperatura de pared favorece la evaporación, lo que a su vez genera un ligero incremento en la presión del sistema, y con ella, la temperatura de ebullición (también evidenciado por Maximo *et al.*, 2010). La concentración de entrada no fue significativa para esta variable.

Por último, la concentración de entrada fue la variable de mayor influencia en el caudal mínimo, seguida de la temperatura de pared. Una disminución en la concentración de entrada de la unidad genera un aumento en el caudal mínimo de operación de 0,2826. Esto se debe a que la viscosidad del jarabe disminuye junto con la concentración (Morison *et al.*, 2006), lo cual impide una distribución uniforme de la película generando “zonas secas” en el evaporador (y un posible daño en el equipo); por lo que se requiere un mayor caudal para asegurar la película en toda la superficie de intercambio. Igualmente, un aumento en la temperatura de pared en una unidad incrementa el caudal mínimo en 0,1017. Esto se debe a que se producen tasas de evaporación más altas, lo que también genera “zonas secas” en el evaporador (Morison *et al.*, 2006).

Entrenamiento de la red y simulación del proceso de evaporación de película descendente con gas de arrastre.


Para realizar el entrenamiento, se suministraron a la red los datos experimentales del proceso de evaporación de película con gas de arrastre (ver Anexo 5). Como resultado de dicho procedimiento se obtuvo un error MSE de 0,0001 aproximadamente en el sexto entrenamiento, como se muestra en la Tabla 8.

Tabla 8. Resultados de los entrenamientos realizados a la red con los datos del proceso de evaporación de película con gas de arrastre. Fuente: Autores.

Entrenamiento	Iteraciones	Error MSE
1	11	0,0027
2	9	0,0025
3	9	0,0024
4	7	0,0023
5	8	0,0010
6	7	0,0001

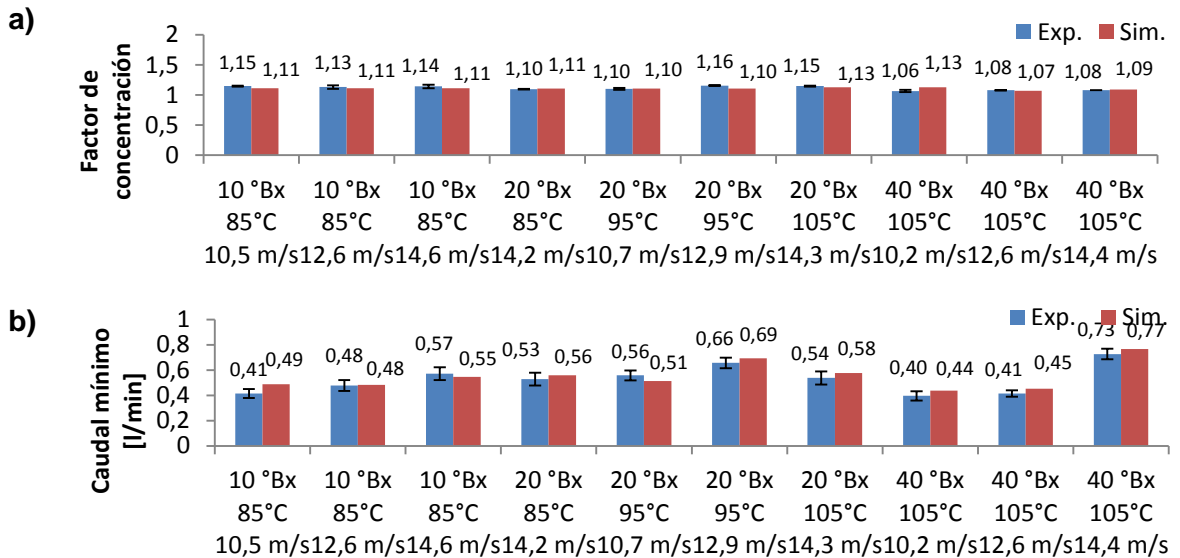
En esta tabla se muestran el número de iteraciones correspondientes a cada uno de los entrenamientos de la red. Posteriormente, se realizó el proceso de validación de la red. Para esto se analizó su capacidad predictiva con una comparación entre los datos experimentales y los simulados. En la Figura 8 se presenta una regresión lineal entre los datos predichos por la red y los experimentales.

Figura 8. Regresión lineal entre los datos experimentales y los predichos por la red para la evaporación de película con gas de arrastre. Fuente: Autores.



De esta figura puede observarse que el coeficiente de determinación (R cuadrado) es superior a 0,99. Estos resultados fueron similares a los obtenidos para el proceso al vacío, y permitieron confirmar la eficacia del entrenamiento. En la Figura 9 se presenta una comparación más directa entre algunos datos experimentales y los obtenidos con la red (Ver Anexo 5).

Figura 9. Variables del proceso de evaporación de película descendente obtenidos experimentalmente y los predichos por la red neuronal. a) Factor de concentración y b) Caudal mínimo requerido para la formación de la película. Fuente: Autores.



En este caso se obtuvieron errores promedio de 1,47% y 6,57% en la predicción del factor de concentración y el caudal mínimo requerido (para formación de la película), respectivamente. Estos errores son ligeramente más altos a los obtenidos en la simulación para la evaporación de película al vacío. Sin embargo, estos resultados siguen siendo menores a los reportados por El-Genk & Saber (2000) (20% de error para el grosor mínimo de película).

Análisis de influencia de las variables de entrada en la evaporación de película descendente con gas de arrastre.

Para este análisis se trabajó con los rangos en las variables de entrada considerados para el entrenamiento de la red en la configuración con gas de arrastre. Los niveles de cada variable del diseño experimental factorial multinivel se especifican en la Tabla 9.

Tabla 9. Factores del diseño experimental del proceso de evaporación de película descendente con gas de arrastre y sus respectivos niveles. Fuente: Autores.

Variable	Concentración de entrada (Ce) [°Brix]	Velocidad del gas (Vg) [m/s]	Temperatura del gas (Tg) [°C]
Niveles	10, 15, 20, 25, 30, 35, 40	10; 10,5; 11; 11,5; 12; 12,5; 13; 13,5; 14; 14,5	85, 90, 95, 100, 105

Después del proceso de simulación, se realizó el análisis estadístico para identificar las variables de mayor influencia en el proceso. Los resultados se presentan en la Tabla 10. Cabe resaltar que la temperatura de salida de la solución no fue analizada, debido a que su valor siempre se mantuvo entre 75-80°C a una temperatura de solución de entrada constante de 80°C (las

temperaturas de salida inferiores a 80°C indican pérdidas de energía durante el proceso).

Tabla 10. Análisis de varianza para el factor de concentración (F_c) y el caudal mínimo de operación (Q_{min}). Fuente: Autores.

Variable*	F_c		Q_{min}	
	Efecto	Valor-P	Efecto	Valor-P
C_e	-0,0423	0,0000	0,0001	0,9918
T_g	0,0111	0,0000	0,0638	0,0000
V_g	0,0461	0,0000	0,1065	0,0000

* C_e : Concentración de entrada; T_g : Temperatura del gas; V_g : Velocidad del gas.

De acuerdo con la información presentada, se observa que la velocidad del aire es la variable de mayor influencia en el factor de concentración, seguida por la concentración de alimentación y la temperatura del aire (de acuerdo con los valores de los efectos). El signo del efecto de la concentración de alimentación sobre el factor de concentración es negativo, es decir que un aumento de esta variable induce una reducción en el factor de concentración. Esto se debe a que la viscosidad aumenta a mayores concentraciones, reduciendo la transferencia de energía (Chen & Jebson, 1997). Esta disminución afecta la evaporación y, por lo tanto, la concentración a la salida. Por otro lado, el efecto de la velocidad del aire en el factor de concentración es positivo. Esto se debe a que un aumento en la velocidad del aire viene acompañado por un aumento en su flujo. Esto incrementa la cantidad de agua que el aire puede retirar a la solución, concentrándola más rápidamente (Geankoplis, 1998). Al igual que la concentración de entrada y la velocidad del gas, la temperatura del gas presenta un efecto significativo (valor $P < 0,05$). Su efecto en el factor de concentración es positivo, debido a que un aumento en la temperatura del gas favorece la evaporación (Geankoplis, 1998).

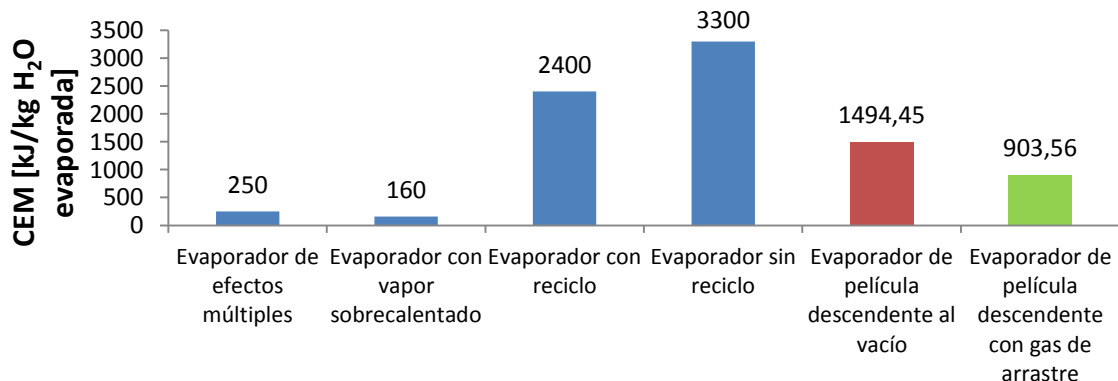
Por otro lado, la variable con la mayor influencia en el caudal mínimo de operación (para la formación de la película) fue la velocidad del aire. En la Tabla 10 puede observarse que un aumento en la velocidad del aire produce un aumento en el caudal mínimo de operación. Esto se debe a que una mayor velocidad de aire favorece la evaporación (como se explicó anteriormente), lo que genera una disminución en el grosor de la película. Dicha disminución puede provocar la aparición de zonas secas en el tubo (Morison *et al.*, 2006), por lo que el caudal debe ser aumentado para eliminarlas. Por otro lado, la variable con la segunda influencia más significativa fue la temperatura del aire. Un aumento en esta variable ocasiona un aumento en el caudal mínimo. Este comportamiento se debe al incremento de la evaporación en la interfase con la temperatura del aire (Geankoplis, 1998), reduciendo el espesor de la película. Como se explica anteriormente, esto puede generar zonas secas en el tubo, por lo que el caudal debe ser aumentado. No se encontró efecto significativo en el flujo de gas sobre esta variable.

Puede observarse que para la evaporación de película al vacío los factores de concentración alcanzados fueron mayores a los obtenidos con gas de arrastre (valores de hasta 1,26 para vacío y hasta 1,16 para gas de arrastre). Por otro lado, el caudal mínimo requerido fue menor para la evaporación al vacío que en la que se utilizó gas de arrastre (valores de $0,29 \pm 0,09$ y $0,68 \pm 0,08$ l/min para vacío y gas de arrastre, respectivamente). Esto se debe a que en la evaporación al vacío hay formación de burbujas, lo que mejora la formación de una película uniforme en la superficie de intercambio y evita la aparición de zonas secas; permitiendo trabajar con menores caudales de alimentación. Esto mejora la transferencia y asegura mayores factores de concentración.

Cálculos de coeficientes energéticos y comparación con otros procesos de evaporación.

En la Figura 10 se presenta una comparación entre el gasto energético de las técnicas de evaporación estudiadas a las mejores condiciones (ver Anexo 6) y otros tipos de evaporación. Puede observarse que el gasto energético de los procesos estudiados es mayor que el necesario para evaporadores de múltiple efecto. Esto se debe a que, a diferencia de los evaporadores de efecto múltiple, el evaporador de película descendente utilizado en este estudio es de un solo efecto. No obstante, dicho gasto energético fue menor que el necesario para los procesos con evaporadores convencionales con y sin reciclo. También puede observarse que se requiere menos energía usando gas de arrastre que con la configuración con vacío. Esto se debe a que la transferencia de calor en el sistema de calentamiento en gas de arrastre es directa y, por lo tanto, más eficiente.

Figura 10. Comparación entre el Consumo Energético Másico (CEM) bajo las mejores condiciones de operación encontradas y otros métodos de evaporación (Anexo 6). Fuente: Cetiat, 2000.



Por último se realizó el cálculo del coeficiente de transferencia de energía para el proceso de evaporación a las mejores condiciones, utilizando la siguiente expresión (Adib *et al.*, 2009):

$$h = 28.34\phi^{0.34}X^{-0.53}\Gamma^{0.2}\theta_L^{1.24}$$

Donde,

h es el coeficiente de transferencia de calor en $Wm^{-2}C^{-1}$

ϕ es el flujo de calor en Wm^{-2}

X es la concentración en $kg\ sólido/kg$

Γ es el flujo de masa por unidad de longitud del tubo en $kg\ m^{-1}s^{-1}$

θ_L es la temperatura de ebullición en $^{\circ}C$

Como resultado se obtuvo un coeficiente de $5307,36\ W\ m^{-2}C^{-1}$ en la evaporación de película descendente al vacío (este cálculo no se realizó para gas de arrastre, pues no se cuenta con los datos necesarios para calcular el flujo de calor). En la Tabla 11 se muestra dicho valor, así como el rango en el que se encuentra ese coeficiente para otros procesos de evaporación.

Tabla 11. Coeficientes globales de transferencia de calor en evaporadores. Fuente: Dutta (2006) y Autores.

Tipo de evaporador	$W.m^{-2}C^{-1}$
Evaporadores de tubo largo	
Circulación natural	1 000 - 2 700
Circulación forzada	2 000 - 7 500
Evaporador de tubo corto	750 - 2 500
Evaporador de película agitado	
Viscosidad baja a media (<1 P)	1 800 – 2 700
Alta viscosidad (> 1P)	1 500
Evaporador de película descendente (viscosidad <0.1 P)	500 – 2 500
Evaporador de película ascendente	2 000 – 5 000
Evaporador de película descendente al vacío usado	5 307,96

Puede observarse que el coeficiente obtenido para el evaporador de película descendente al vacío usado es mayor a los rangos establecidos para su valor. Esto muestra la eficiencia del piloto utilizado para llevar a cabo los experimentos. En cuanto a los factores de concentración, los resultados fueron menores a los encontrados en el estudio con película ascendente realizado por Rodríguez & Sandoval (2011), que obtuvieron valores del orden de 1,4. Esto se debe a que los tiempos de residencia de la solución dentro del evaporador de película descendente (al vacío y con gas de arrastre) no excedían los 10s; comparado con los más de 2 min de duración en el estudio de evaporación con película ascendente. Tiempos de residencia mayores aumentan la transferencia de energía, y por consiguiente, el factor de concentración. Además, la longitud del piloto (1,44 m) es corta en comparación con los evaporadores de película descendente industriales, que pueden llegar a tener hasta 15 m de altura. Es importante señalar que en el estudio del proceso de evaporación de película descendente no se evidenció ensuciamiento en la superficie de intercambio del evaporador, fenómeno que si fue reportado para el proceso en película ascendente. El ensuciamiento afecta la calidad del producto, además de generar aumento de costos y disminución del tiempo de operación por paradas del sistema para limpieza.

CONCLUSIONES

- Se diseñó la arquitectura de una red neuronal *Feedforward* para simular la evaporación de película descendente, al vacío y con gas de arrastre, a partir de un diseño experimental. Como resultado, los mejores valores establecidos para dicha arquitectura que aseguraban disminuir el error de entrenamiento (MSE) fueron: algoritmo de entrenamiento de *Levenberg-Maquardt*, 2 capas ocultas, 30 neuronas/capa oculta y 60% de información de entrenamiento. A partir de esta arquitectura se obtuvieron errores MSE entre 0,12 y 0,001.
- A partir de este diseño de arquitectura de red, se realizó su entrenamiento y posterior validación de los resultados. Se obtuvo un modelo capaz de predecir de manera rápida y sencilla variables de un proceso complejo como la evaporación de película descendente. Para la evaporación de película al vacío se obtuvieron errores promedios de 0,83%; 0,17% y 5,24% en la predicción del factor de concentración, la temperatura de salida y el caudal mínimo de operación, respectivamente. En la evaporación con gas de arrastre el error en la predicción del factor de concentración fue de 1,47%; mientras que para el caudal mínimo requerido fue de 6,57%.
- Por último, se analizó la influencia de las variables del proceso. Se encontró que para la evaporación de película descendente al vacío, la variable de mayor influencia en el factor de concentración y el caudal mínimo de operación fue la concentración de entrada (con efectos de -0,1348 y -0,2826; respectivamente). La presión de vacío no tuvo un efecto significativo en ninguna de las dos. Sin embargo, esta variable tuvo el mayor efecto en la temperatura de salida, con un efecto de 8,4326. Asimismo, en el proceso con gas de arrastre se determinó que, de las tres variables estudiadas, la velocidad del gas es la de mayor influencia en el factor de concentración y el caudal mínimo de operación (con efectos de 0,0461 y 0,1065; respectivamente).

Recomendaciones para trabajos futuros.

- Mejorar el piloto de manera que permita la medición de la temperatura del aire a la salida del evaporador. Esto con el propósito de poder realizar cálculos energéticos y determinar la eficiencia del piloto.
- Evaluar el uso de redes neuronales para el control de las variables del piloto de evaporación de película descendente (al vacío y con gas de arrastre).
- Incorporar al piloto un sensor de presión con mayor sensibilidad, de manera que puedan llevarse a cabo estudios a menores presiones de vacío.

BIBLIOGRAFÍA

- ADIB T.A.; HEYD B.; VASSEUR J. Experimental results and modeling of boiling heat transfer coefficients in falling film evaporator usable for evaporator design. *Chemical Engineering and Processing* 48 (2009); págs. 961–968.
- ASSAD M.; LAMPINEN M. Mathematical modeling of falling liquid film evaporation process. *International Journal of Refrigeration* 25 (2002); págs. 985–991.
- BHARGAVAA R., KHANAMB S., MOHANTYA B., RAYC A.K. Simulation of flat falling film evaporator system for concentration of black liquor. *Computers and Chemical Engineering* 32 (2008); págs. 3213–3223
- BASHEER I.A.; HAJMEER M. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods* 43 (2000); págs. 3–31.
- BATISTELLA C.B.; MACIEL M.R.W. Modeling, simulation and analysis of molecular distillators: centrifugal and falling film. *Computers Chem. Eng.* Vol. 20 (1996); págs. 19-24.
- BENAVIDES O.; GUEVARA C. Planteamiento de un modelo matemático para la transferencia de masa en el proceso de concentración de etanol utilizando destilación con membranas. Tesis de pregrado en Ingeniería Química. Facultad de ingenierías fisicoquímicas. Universidad Industrial de Santander 2010. 58 p.
- BHARGAVA R., KHANAM S., MOHANTY B., Ray A.K. Simulation of flat falling film evaporator system for concentration of black liquor. *Computers and Chemical Engineering* 32 (2008); págs. 3213–3223.
- BROTHERTON F. Alcohol recovery in falling film evaporators. *Applied Thermal Engineering* 22 (2002); págs. 855–860.
- CHEN H.; JEBSON R. S. Factors affecting heat transfer in falling film evaporators. *Trans IChemE Vol. 75. Part C* (1997); págs. 111-116.
- DIRION J.L.; CABASSUD M.; CASAMATTA G.; LE LANN M.V. Neural networks for process control: application to the temperature control of batch

chemical reactors. *Expert Systems*, Edited by Cornelius T. Leondes, Vol. 2 (2002); págs. 443-488.

- EL-GENK M.S.; SABER H. Minimum thickness of a flowing down liquid film on a vertical surface. *International Journal of Heat and Mass Transfer* 44 (2001); págs. 2809-2825.
- FEDDAOUI M.; MEFTAH H.; MIR A. The numerical computation of the evaporative cooling of falling water film in turbulent mixed convection inside a vertical tube. *International Communications in Heat and Mass Transfer* 33 (2006); págs. 917–927.
- FULLANA M.; TRABELSI F.; RECASENS F. Use of neural net computing for statistical and kinetic modelling and simulation of supercritical fluid extractors. *Chemical Engineering Science* 55 (2000); págs. 79-95.
- GEANKOPLIS C.J. *Procesos de transporte y operaciones unitarias*. 3^{ra} edición. Compañía editorial continental S.A. de C.V., México. 1998. 1024 p.
- GERSTBERGER R.; RENTROP P. Feedforward neural nets as discretization schemes for ODEs and DAEs. *Journal of Computational and Applied Mathematics* 82 (1997); págs. 117-128.
- HAGAN, M.; DEMUTH, H.; BEALE, M. *Neural network design*. Citic publishing house (1996). 734 p.
- HINES M.L.; CARNEVALE N.T. Discrete event simulation in the NEURON environment. *Neurocomputing* 58–60 (2004); págs. 1117 – 1122.
- JEONG K.; JOO G.; KIM H.; HA K.; RECKNAGEL F. Prediction and elucidation of phytoplankton dynamics in the Nakdong River (Korea) by means of a recurrent artificial neural network. *Ecological Modelling* 146 (2001); págs. 115–129.
- LENNOX B.; MONTAGUE G.; FRITH A.; GENT C.; BEVAN V. Industrial application of neural networks – an investigation. *Journal of Process Control* 11 (2001); págs. 497-507.
- LI W.; WU X.; LUO Z.; WEBB R. Falling water film evaporation on newly-designed enhanced tube bundles. *International Journal of Heat and Mass Transfer* 54 (2011); págs. 2990–2997.

- LIU, Z.; YI, J. Falling film evaporation heat transfer of water/salt mixtures from roll-worked enhanced tubes and tube bundle. *Applied thermal engineering* 22 (2002); págs. 83-95.
- MACHÓN I.; LÓPEZ H.; RODRIGUEZ-IGLESIAS J.; MARAÑÓN E.; VÁZQUEZ I. Simulation of a coke wastewater nitrification process using a feed-forward neuronal net. *Environmental Modelling & Software* 22 (2007); págs. 1382-1387.
- MAXIMO G., MEIRELLES A., BATISTA E. Boiling point of aqueous d-glucose and d-fructose solutions: Experimental determination and modeling with group-contribution method. *Fluid Phase Equilibria* 299 (2010); págs. 32–41.
- MENÉNDEZ DE LLANO R., BOSQUE J. Study of neural net training methods in parallel and distributed architectures. *Future Generation Computer Systems* 26 (2010); págs. 267-275.
- MORISON K. R., WORTH Q. A. G.; O'DEA N. P. Minimum wetting and distribution rates in falling film evaporators. *Food and Bioprocess Processing*, 84 (2006); págs. 302–310.
- MULAS M.; MASSOBRIO P. NeuVision: A novel simulation environment to model spontaneous and stimulus-evoked activity of large-scale neuronal networks. *Neurocomputing* (2013); págs. 1-17.
- NAKORYAKOV V.; GRIGORYEVA N.; BARTASHEVICH M. Heat and mass transfer in the entrance region of the falling film: Absorption, desorption, condensation and evaporation. *International Journal of Heat and Mass Transfer* 54 (2011); págs. 4485–4490.
- PACHECO C.R.F.; FRIONI L.S.M. Experimental results for evaporation of sucrose solution using a climbing/falling film plate evaporator. *Journal of Food Engineering* 64 (2004); págs. 471–480.
- PIOTROWSKI A., NAPIORKOWSKI J. A comparison of methods to avoid overfitting in neural networks training in the case of catchment runoff modelling. *Journal of Hydrology* 476 (2013); págs. 97-111.
- RODRÍGUEZ S.; SANDOVAL J. Obtención de jarabes de glucosa a partir de la hidrólisis del almidón de yuca: etapas de preconcentración y

concentración. Tesis de pregrado en Ingeniería Química. Facultad de ingenierías fisicoquímicas. Universidad Industrial de Santander 2011. 42 p.

- SOLANO R., MUÑOZ C. Construcción e implementación de un piloto laboratorio de evaporación de película descendente. Tesis de pregrado en Ingeniería Química. Facultad de ingenierías fisicoquímicas. Universidad Industrial de Santander 2014. 44 p.
- VELÁSQUEZ J., DYNER I., SOUZA R. Tendencias en la predicción y estimación de los intervalos de confianza usando modelos de redes neuronales aplicados a series temporales. *Dyna* 149 (2006); págs. 141-147.
- ZHANG L., SUBBARAYAN G. An evaluation of back-propagation neural networks for the optimal design of structural systems: Part I. Training procedures. *Comput. Methods Appl. Mech. Engrg.* 191 (2002); págs. 2873–2886.

Anexo A

Tabla A. Diseño experimental y análisis de influencia de los parámetros de red sobre su capacidad predictiva. Fuente: Autores.

Capas	Neuronas	Training	Exp.	MSE1	MSE2	MSE3	Prom.	Desv.	
1	10	30	20	0,029	0,006	0,012	0,016	0,047	
			60	0,006	0,025	0,010	0,014	0,009	
			100	0,009	0,006	0,007	0,007	0,002	
		60	20	0,206	0,112	0,172	0,163	0,047	
			60	0,019	0,003	0,004	0,008	0,009	
			100	0,005	0,009	0,002	0,005	0,004	
		90	20	0,013	0,002	0,053	0,023	0,027	
			60	0,011	0,004	0,010	0,008	0,004	
			100	0,012	0,005	0,005	0,007	0,004	
	30	30	20	0,024	0,001	0,006	0,010	0,012	
			60	0,017	0,003	0,009	0,010	0,007	
			100	0,018	0,009	0,003	0,010	0,007	
		60	20	0,460	0,893	0,095	0,483	0,400	
			60	0,122	0,069	0,126	0,106	0,032	
			100	0,018	0,009	0,016	0,015	0,005	
		90	20	0,002	0,007	0,019	0,009	0,009	
			60	0,022	0,014	0,003	0,013	0,010	
			100	0,004	0,010	0,009	0,008	0,003	
	50	30	20	0,037	0,013	0,004	0,018	0,017	
			60	0,006	0,013	0,001	0,007	0,006	
			100	0,001	0,001	0,001	0,001	0,000	
		60	20	0,475	0,362	0,113	0,317	0,185	
			60	0,211	0,036	0,027	0,091	0,104	
			100	0,010	0,007	0,014	0,011	0,003	
		90	20	0,000	0,001	0,000	0,001	0,000	
			60	0,005	0,001	0,001	0,002	0,003	
			100	0,002	0,001	0,005	0,003	0,002	
	2	10	30	20	0,008	0,011	0,004	0,008	0,004
				60	0,008	0,015	0,012	0,012	0,003
				100	0,015	0,004	0,008	0,009	0,006
			60	20	0,132	0,157	0,087	0,125	0,035
				60	0,057	0,013	0,009	0,026	0,027
				100	0,012	0,022	0,009	0,015	0,007
			90	20	0,000	0,000	0,003	0,001	0,002
				60	0,015	0,048	0,095	0,052	0,040
				100	0,008	0,009	0,004	0,007	0,003

	30	30	20	0,008	0,008	0,002	0,006	0,003		
			60	0,006	0,009	0,005	0,007	0,002		
			100	0,004	0,007	0,003	0,005	0,002		
		60	20	0,355	0,089	0,020	0,155	0,177		
			60	0,033	0,013	0,008	0,018	0,013		
			100	0,008	0,024	0,004	0,012	0,011		
		90	20	0,001	0,003	0,005	0,003	0,002		
			60	0,001	0,003	0,002	0,002	0,001		
			100	0,002	0,002	0,001	0,002	0,001		
		50	30	20	0,014	0,005	0,016	0,012	0,006	
				60	0,062	0,008	0,043	0,038	0,027	
				100	0,020	0,008	0,015	0,014	0,006	
	60		20	0,274	0,220	0,025	0,173	0,131		
			60	0,014	0,106	0,017	0,046	0,052		
			100	0,029	0,009	0,009	0,016	0,012		
	90		20	0,007	0,001	0,068	0,025	0,037		
			60	0,016	0,011	0,010	0,012	0,003		
			100	0,018	0,019	0,005	0,014	0,008		
	3		10	30	20	0,008	0,004	0,011	0,008	0,003
					60	0,007	0,004	0,011	0,007	0,003
					100	0,007	0,005	0,004	0,005	0,001
		60		20	0,013	0,101	0,008	0,041	0,053	
				60	0,027	0,007	0,017	0,017	0,010	
				100	0,030	0,017	0,005	0,017	0,013	
90		20		0,001	0,015	0,002	0,006	0,008		
		60		0,011	0,003	0,004	0,006	0,004		
		100		0,006	0,002	0,009	0,006	0,003		
30		30		20	0,023	0,025	0,009	0,019	0,009	
				60	0,015	0,011	0,013	0,013	0,002	
				100	0,009	0,026	0,018	0,017	0,009	
		60	20	0,083	0,008	0,161	0,084	0,077		
			60	0,052	0,016	0,040	0,036	0,018		
			100	0,016	0,024	0,012	0,018	0,006		
		90	20	0,016	0,008	0,018	0,014	0,005		
			60	0,019	0,008	0,009	0,012	0,006		
			100	0,010	0,014	0,075	0,033	0,037		
		50	30	20	2,259	1,694	0,612	1,522	0,837	
				60	0,417	0,141	0,158	0,239	0,155	
				100	0,085	0,141	0,020	0,082	0,060	
60			20	0,041	0,082	0,260	0,128	0,116		
			60	0,092	0,031	0,106	0,077	0,040		
			100	0,092	0,019	0,011	0,041	0,045		

		90	20	0,093	0,000	0,066	0,053	0,048
			60	0,040	0,030	0,021	0,030	0,009
			100	0,006	0,003	0,005	0,004	0,001

Anexo B

Tabla A. Datos experimentales del proceso de evaporación de película descendente al vacío. Fuente: Autores.

VARIABLES DE ENTRADA			VARIABLES DE SALIDA					
<i>Ce</i> [°Brix]	<i>Pv</i> [mbar]	<i>Tp</i> [°C]	<i>Fc</i>	<i>Ts</i> [°C]	<i>Qmín</i> [l/min]	<i>Fc</i>	<i>Ts</i> [°C]	<i>Qmín</i> [l/min]
10	200	80	1,16	63	0,360	1,20	63	0,331
10	200	85	1,24	63	0,311	1,22	63	0,352
10	200	90	1,25	63	0,264	1,26	63	0,225
10	250	80	1,20	67	0,422	1,20	67	0,484
10	250	85	1,16	67	0,348	1,20	67	0,403
10	250	90	1,24	68	0,400	1,20	68	0,371
10	300	80	1,18	71	0,413	1,20	71	0,381
10	300	85	1,26	71	0,349	1,24	71	0,302
10	300	90	1,20	71	0,428	1,23	71	0,387
20	200	80	1,05	62	0,217	1,05	62	0,201
20	200	85	1,01	62	0,248	1,06	62	0,230
20	200	90	1,13	62	0,258	1,16	62	0,297
20	250	80	1,06	67	0,175	1,06	67	0,187
20	250	85	1,10	67	0,212	1,09	67	0,233
20	250	90	1,12	67	0,326	1,13	67	0,290
20	300	80	1,05	70	0,302	1,06	71	0,291
20	300	85	1,10	71	0,197	1,08	71	0,221
20	300	90	1,10	71	0,368	1,10	71	0,355
40	200	80	1,13	63	0,270	1,16	63	0,310
40	200	85	1,11	63	0,175	1,14	63	0,154
40	200	90	1,13	64	0,318	1,13	64	0,306
40	250	80	1,06	67	0,227	1,06	67	0,198
40	250	85	1,07	67	0,190	1,05	68	0,220
40	250	90	1,10	67	0,209	1,08	68	0,240
40	300	80	1,11	71	0,258	1,15	71	0,224
40	300	85	1,09	71	0,195	1,08	71	0,176
40	300	90	1,16	72	0,290	1,18	72	0,329

Anexo C

Tabla A. Resultados de la simulación de la evaporación de película descendente al vacío con redes neuronales. Fuente: Autores.

VARIABLES DE ENTRADA			VARIABLES DE SALIDA		
C_e [°Brix]	P_v [mbar]	T_p [°C]	C_s [°Brix]	T_s [°C]	$Q_{mín}$ [l/min]
10	200	80	1,2	63	0,331
10	200	85	1,24	62,89	0,306
10	200	90	1,26	63,01	0,225
10	250	80	1,2	67	0,484
10	250	85	1,16	67,03	0,348
10	250	90	1,22	67,95	0,411
10	300	80	1,18	71,04	0,411
10	300	85	1,25	71,03	0,334
10	300	90	1,2	70,99	0,429
20	200	80	1,04	62,04	0,200
20	200	85	1,1	62	0,254
20	200	90	1,14	62	0,266
20	250	80	1,07	67,01	0,178
20	250	85	1,09	67,03	0,211
20	250	90	1,13	67	0,280
20	300	80	1,05	69,9	0,274
20	300	85	1,1	70,97	0,201
20	300	90	1,09	71,41	0,373
40	200	80	1,16	63,52	0,260
40	200	85	1,14	63	0,168
40	200	90	1,12	62,98	0,311
40	250	80	1,05	66,99	0,231
40	250	85	1,05	66,98	0,215
40	250	90	1,09	66,96	0,210
40	300	80	1,1	70,98	0,217
40	300	85	1,1	70,98	0,215
40	300	90	1,16	72,04	0,277

Anexo D

Tabla A. Datos experimentales del proceso de evaporación de película descendente con gas de arrastre. Fuente: Autores.

VARIABLES DE ENTRADA			VARIABLES DE SALIDA					
C_e [°Brix]	T_{aire} [°C]	F_{aire} [m/s]	F_c	T_s [°C]	Q_{min} [l/min]	F_c	T_s [°C]	Q_{min} [l/min]
10	85	10,53	1,12	78	0,656	1,11	76	0,617
10	85	12,58	1,14	75	0,594	1,15	75	0,656
10	85	14,59	1,15	75	0,721	1,16	75	0,787
10	95	10,50	1,10	77	0,660	1,12	77	0,620
10	95	12,66	1,13	79	0,652	1,14	77	0,696
10	95	14,45	1,16	75	0,726	1,15	76	0,784
10	105	10,31	1,12	78	0,665	1,10	77	0,628
10	105	12,65	1,12	78	0,657	1,11	76	0,740
10	105	14,56	1,13	78	0,760	1,14	77	0,696
20	85	10,73	1,10	74	0,403	1,10	78	0,471
20	85	12,52	1,12	79	0,702	1,10	79	0,736
20	85	14,18	1,13	77	0,663	1,09	75	0,677
20	95	10,71	1,11	76	0,668	1,09	76	0,736
20	95	12,19	1,14	80	0,755	1,14	80	0,751
20	95	14,33	1,15	78	0,693	1,16	75	0,801
20	105	10,35	1,13	75	0,701	1,14	77	0,654
20	105	12,49	1,15	76	0,770	1,15	76	0,700
20	105	14,31	1,16	76	0,721	1,17	77	0,731
40	85	10,14	1,05	75	0,498	1,05	75	0,575
40	85	12,20	1,06	76	0,717	1,06	75	0,709
40	85	14,14	1,06	75	0,626	1,06	76	0,676
40	95	10,36	1,08	77	0,531	1,09	76	0,609
40	95	12,28	1,09	76	0,739	1,09	76	0,658
40	95	14,39	1,09	75	0,775	1,10	75	0,885
40	105	10,20	1,08	77	0,639	1,08	76	0,572
40	105	12,61	1,08	77	0,713	1,08	76	0,620
40	105	14,39	1,08	75	0,675	1,08	75	0,609

Anexo E

Tabla A. Resultados de la simulación de la evaporación de película descendente con gas de arrastre con redes neuronales. Fuente: Autores.

VARIABLES DE ENTRADA			VARIABLES DE SALIDA	
C_e [°Brix]	T_{aire} [°C]	F_{aire} [m/s]	F_c	Q_{min} [l/min]
10	85	10,53	1,12	0,588
10	85	12,58	1,15	0,698
10	85	14,59	1,13	0,706
10	95	10,50	1,12	0,655
10	95	12,66	1,13	0,667
10	95	14,45	1,15	0,752
10	105	10,31	1,11	0,666
10	105	12,65	1,11	0,685
10	105	14,56	1,15	0,758
20	85	10,73	1,12	0,520
20	85	12,52	1,15	0,740
20	85	14,18	1,13	0,674
20	95	10,71	1,11	0,749
20	95	12,19	1,14	0,737
20	95	14,33	1,15	0,748
20	105	10,35	1,13	0,700
20	105	12,49	1,13	0,654
20	105	14,31	1,16	0,723
40	85	10,14	1,06	0,619
40	85	12,20	1,06	0,718
40	85	14,14	1,09	0,641
40	95	10,36	1,06	0,600
40	95	12,28	1,08	0,727
40	95	14,39	1,07	0,953
40	105	10,20	1,08	0,575
40	105	12,61	1,09	0,635
40	105	14,39	1,08	0,675

Anexo F

Tabla A. Mejores condiciones del proceso de evaporación de película descendente al vacío. Fuente: Autores.

Variable	Concentración de entrada	Temperatura de Pared	Presión de vacío	Temperatura de alimentación
Valor	10	90	200	57

Tabla B. Mejores condiciones para el proceso de evaporación de película descendente con gas de arrastre: Fuente: Autores.

Variable	Concentración de entrada	Temperatura de Gas	Velocidad de gas
Valor	10	105	14,5