

# Modelo basado en redes neuronales artificiales para el cálculo de parámetros ambientales en el proceso de curado del tabaco

## Artificial neural network based model to calculate the environmental variables of the tobacco drying process

Recibido: 13-03-2013 Aceptado: 24-04-2013

VÍCTOR MARTÍNEZ-MARTÍNEZ<sup>1</sup>

CARLOS BALADRÓN<sup>2</sup>

JAIME GÓMEZ-GIL<sup>3</sup>

GONZALO RUIZ-RUIZ<sup>4</sup>

LUIS M. NAVAS-GRACIA<sup>5</sup>

JAVIER M. AGUIAR<sup>6</sup>

BELÉN CARRO<sup>7</sup>

### Resumen

Se presenta un modelo basado en Redes Neuronales Artificiales (RNA) para las variables ambientales relativas al proceso de curado de Tabaco. Una RNA de ajuste se empleó para estimar y predecir la temperatura y la humedad relativa en el interior del secadero de tabaco: la estimación consiste en calcular el valor de estas variables en diferentes localizaciones del interior del secadero y la predicción consiste en vaticinar el valor de dichas variables con diferentes horizontes temporales. El modelo propuesto ha sido validado con datos de temperatura y humedad relativa adquiridos de un secadero de tabaco real utilizando una red de sensores inalámbricos (wireless sensor network, WSN). Por una parte, en la etapa de estimación se consiguió un error inferior al 2%, calculando la temperatura en función de la temperatura y la humedad relativa en otros puntos del secadero. Por otra parte, en la etapa de predicción se consiguió un error 1,5 veces inferior al obtenido con un método basado en interpolación, calculando la temperatura futura en el interior de la masa de tabaco con horizontes de predicción superiores a 2,5 horas a partir del valor actual y los valores anteriores de dicha variable. Los resultados muestran que los modelos basados en RNA se pueden utilizar para mejorar el proceso de curado del tabaco porque el valor de las variables ambientales relacionadas se puede predecir en instantes futuros cercanos y se puede estimar en otras localizaciones con errores pequeños utilizando este tipo de modelos.

**Palabras clave:** Tabaco curado; modelado de procesos, redes neuronales; estimación, predicción.

### Abstract

This paper presents an Artificial Neural Network (ANN) based model for environmental variables related to the tobacco drying process. A fitting ANN was used to estimate and predict temperature and relative humidity inside the tobacco dryer: the estimation consists of calculating the value of these variables in different locations of the dryer and the prediction consists of forecasting the value of these variables with different time horizons. The proposed model has been validated with temperature and relative humidity data obtained from

- 1 MS.c. Departamento de Teoría de la Señal, Comunicaciones e Ingeniería Telemática, Universidad de Valladolid, España. vmarmar@ribera.tel.uva.es
- 2 Ph.D. Departamento de Ingeniería Agrícola y Forestal, Universidad de Valladolid, España. cbalzar@ribera.tel.uva.es
- 3 Ph.D. Departamento de Teoría de la Señal, Comunicaciones e Ingeniería Telemática, Universidad de Valladolid, España. jgomez@tel.uva.es
- 4 MS.c. Departamento de Ingeniería Agrícola y Forestal, Universidad de Valladolid, España. gruiz@iaf.uva.es
- 5 Ph.D. Departamento de Ingeniería Agrícola y Forestal, Universidad de Valladolid, España. lmnvas@iaf.uva.es
- 6 Ph.D. Departamento de Teoría de la Señal, Comunicaciones e Ingeniería Telemática, Universidad de Valladolid, España. javagu@tel.uva.es
- 7 Ph.D. Departamento de Teoría de la Señal, Comunicaciones e Ingeniería Telemática, Universidad de Valladolid, España. belcar@tel.uva.es

a real tobacco dryer using a Wireless Sensor Network (WSN). On the one hand, an error under 2% was achieved, obtaining temperature as a function of temperature and relative humidity in other locations in the estimation task. Besides, an error around 1.5 times lower than the one obtained with an interpolation method was achieved in the prediction task when the temperature inside the tobacco mass was predicted with time horizons over 2.5 hours as a function of its present and past values. These results show that ANN-based models can be used to improve the tobacco drying process because with these types of models the value of environmental variables can be predicted in the near future and can be estimated in other locations with low errors.

**Keywords:** flue-cured tobacco, process modeling, neural networks, estimation, prediction.

## Introducción

El cultivo del tabaco es una de las principales actividades económicas en zonas agrícolas de países como Brasil, China e India (Nations y Commodities Trade Division Agriculture Organization of the United Nations. Raw Materials 2003). En las últimas décadas, un gran número de innovaciones tecnológicas aplicadas a este cultivo se han desarrollado en diferentes aspectos como la maquinaria, las técnicas de cultivo y las técnicas de secado. Además, el proceso de curado del tabaco ha sido estudiado y mejorado mediante el empleo de nuevas estrategias de secado y nueva maquinaria, con el fin de mejorar la calidad del producto final y de aumentar la eficiencia energética global del proceso (Hawks, *et al.*, 1986).

Una de las líneas de modernización de los procesos agrícolas en la actualidad consiste en la supervisión de dicho proceso mediante un sistema de monitorización, el cual se encarga de adquirir y almacenar las variables más importantes de dicho proceso (Frost *et al.*, 1997). Un ejemplo de este avance y de la necesidad de sistemas de monitorización es el proceso de curado del tabaco, que requiere de la supervisión exhaustiva de sus variables más representativas para poder ser optimizado.

Los datos recopilados por sistemas de monitorización se utilizan para analizar las relaciones entre las variables de dicho sistema y proponer con ello un modelo del proceso monitorizado (Yue *et al.*, 2011). Estos modelos se pueden generar mediante técnicas de lógica difusa o fuzzy-logic, con estimadores probabilísticos o con Redes Neuronales Artificiales (RNA) entre otras técnicas. Un ejemplo de modelado de procesos empleando lógica difusa es el trabajo de Papantoniou, con otros autores que propusieron un modelo de potencia eólica en aplicaciones agrícolas (Papantoniou, *et al.*, 1997). Ejemplos de modelos basados en estimadores

probabilísticos pueden ser los modelos demográficos de animales como los realizados en el 2009 por Holland y otros autores. Respecto a las RNA, en 1997, Recknagel y otros autores modelaron el crecimiento de algas; en el 2009, Smith y otros autores, predijeron la temperatura del aire con un modelo basado en RNA; y Singh y otros autores modelaron la calidad del agua.

La aplicación de las herramientas de procesamiento de datos es el control y predicción de variables en procesos agrícolas. Un ejemplo de aplicación de las herramientas en procesos de secado agrícola es el trabajo desarrollado en el 2009 y 2010, por Li y otros autores, que desarrollaron y testearon un algoritmo de control para el secado de vegetales empleando microondas (Li *et al.*, 2009; Li *et al.*, 2010; Li *et al.*, 2010). Otro ejemplo utilizando estimadores probabilísticos es el trabajo desarrollado por Banga y Singh, en 1994, en el que diseñaron un algoritmo de control basado en estimadores estocásticos usando temperatura y humedad relativa como variables de entrada. Por último, las RNA también han sido aplicadas a procesos de secado, como en el trabajo en el que se diseñó un sistema para identificar las dinámicas del proceso de secado en un secador rotatorio (Yliniemi 1999; Yliniemi *et al.*, 1999), o en el trabajo, en el que se propuso un modelo para el secado del tomate que se ajustaba a datos experimentales con mayor precisión que otros modelos matemáticos propuestos en la literatura (Movagharnjad y Nikzad 2007).


En este trabajo se propone y prueba un sistema para estimar y predecir la temperatura y la humedad relativa en el proceso de curado del tabaco. Este sistema adquiere la temperatura y humedad relativa en diferentes puntos dentro del secadero, y procesa los datos adquiridos para poder estimar su valor en otros puntos del secadero o predecir su valor en el futuro. La metodología del artículo se desarrolló en cuatro etapas:

- Un sistema de monitorización basado en una red de sensores inalámbrica (*wireless sensor network*, WSN) fue desarrollado y desplegado en el secadero para adquirir las variables de entrada del sistema.
- Una RNA fue desarrollada para estimar las variables de salida a partir de las variables adquiridas.
- Varios experimentos fueron realizados para analizar los métodos propuestos para la estimación y predicción.
- Los resultados experimentales fueron analizados para evaluar los métodos propuestos.

## Materiales

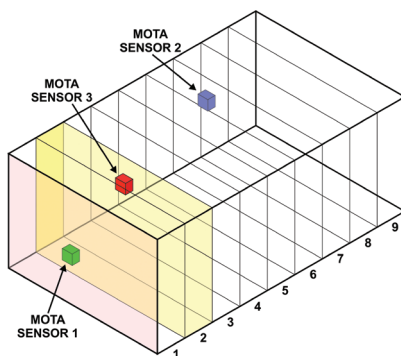
Un secadero de tabaco de la empresa Agrotex localizado en Rosalejo (Cáceres, España) se empleó para este trabajo. Este secadero contaba con una electroválvula de agua caliente para calentar el aire, un ventilador para hacer circular el aire y dos trampillas para dejar salir el aire

húmedo del interior y entrar el aire seco del exterior del secadero. Además, tres motas inalámbricas para la medida de temperatura y humedad relativa en diferentes puntos de la cámara de curado. En la Figura 1 se muestra un esquema de la sección transversal del secadero, donde se pueden ver los componentes anteriormente mencionados. En la Figura 2 se observa la distribución espacial de las tres motas desplegadas en el interior de la cámara de curado: la primera se situó al lado de la ventana de supervisión (verde), la segunda al lado del techo (morado) y la tercera en el interior de la masa de tabaco (rojo). Los sensores relativos a cada una de estas motas de medida han sido numerados como Sensor 1, 2 y 3 respectivamente, para su más fácil referencia en el resto del documento.



**Figura 1.** Sección transversal del secadero de tabaco, donde se muestra el ventilador de aire, la electroválvula de agua y dos trampillas de aire en su situación real.

Una WSN compuesta por motas MEP510 de la empresa Crossbow se empleó para realizar las medidas. Este tipo de motas tienen un sensor digital de humedad modelo SHT11 de la empresa Sensirion para adquirir tanto la temperatura como la humedad relativa. Además se utilizaron las herramientas de modelado LabVIEW y Matlab, para desarrollar las aplicaciones empleadas en la adquisición de los datos de la WSN, el almacenamiento en una base de datos estructurada y en el desarrollo de una RNA para la estimación y predicción de los datos.




**Figura 2.** Distribución espacial de las motas de medida dentro de la cámara de curado: mota cercana a la ventana de supervisión de curado (verde), en el segundo contenedor de tabaco (rojo) y cercana al techo del secadero (morado).

## Métodos

### Proceso de curado del tabaco

El proceso de curado del tabaco estudiado en este trabajo está basado en el incremento progresivo de la temperatura en el interior de la cámara de curado con el fin de extraer la humedad de las hojas de tabaco. Para llevar a cabo este proceso se empleó una temperatura de consigna variable con el tiempo, como la mostrada en la Figura 3. A este gráfico se le denomina curva de curado, y el gráfico mostrado en la Figura 3 representa una curva de curado típica para este tipo de secaderos (Hawks *et al.*, 1986).



**Figura 3.** Evolución de la temperatura de consigna para los procesos de curado analizados.

El proceso de curado se manejó mediante un controlador de propósito general, el cual utilizó un sensor de temperatura para adquirir la temperatura instantánea, el punto de adquisición cercano a la ventana de observación que se mostró en la Figura 2, y ajustó la señal de salida que gobernaba la electroválvula con base en un algoritmo de “todo o nada”: si la temperatura del secadero es mayor que la temperatura de consigna, la electroválvula se desactiva, y si la temperatura del secadero es inferior a la temperatura de consigna la electroválvula se activa. Además, una histéresis de 2 °C se empleó en el algoritmo de control para evitar que la electroválvula se activase y se desactivase con una frecuencia elevada. Por otra parte, la curva de curado consiste en una concatenación de dos tipos de fases: fases de temperatura constante, en las que la temperatura de consigna no varía, y fases de aumento de temperatura con incremento de temperatura constante. Estos dos tipos de fases se pueden distinguir en la Figura 3.

### Datos empleados en el análisis

Se tienen 53.833 minutos de datos del proceso de curado, que equivalen a unas 900 horas y fueron adquiridos para su posterior procesamiento. La temperatura para cada proceso de curado varió entre 20 °C y 75 °C, mientras que la humedad relativa fluctuó entre un 10% y un 100%. Estos datos fueron tomados en la campaña de curado del 2011 en el secadero presentado en la sección de Materiales. Una frecuencia

de muestreo de 3 minutos se empleó para la adquisición de cada variable del proceso de curado, de modo que se utilizaron 216.828 muestras de datos, que corresponden a 37 días de proceso.

## Redes neuronales artificiales

### Objetivo y finalidad

El objetivo de esta sección fue diseñar un sistema basado en RNA para la estimación y predicción de temperatura y humedad relativa en diferentes puntos espaciales y con distintos horizontes de predicción dentro de un secadero de tabaco y con datos adquiridos en diversos puntos de interés dentro del secadero. Esto quiere decir que el sistema diseñó dos tipos de tareas: estimación y predicción. En la estimación de datos, la RNA utilizó los datos de temperatura y humedad relativa obtenidos en un instante temporal  $t$  en un conjunto de puntos de medida para estimar los valores de estas mismas variables para el mismo instante temporal  $t$  en otro punto diferente dentro del secadero. Por otra parte, en la predicción de datos la RNA utilizó los datos de temperatura y humedad relativa adquiridos en una serie de puntos de medida en un instante dado  $t$  y los  $n-1$  instantes temporales anteriores ( $t-1, t-2, \dots, t-n-1$ ) para predecir el valor de esas variables en los mismos puntos de medida para un instante futuro  $t+t_0$ .

### Diseño de la RNA

Normalmente, cuando los datos de trabajo de una RNA son función del tiempo, una solución clásica es el empleo de RNA para series temporales (Dorffner 1996; Hill *et al.*, 1996), esto es, una RNA con una arquitectura con retardos específicamente diseñada para operar con una o varias entradas pertenecientes a secuencias temporales son capaces de estimar el valor de estas secuencias en el futuro.

Sin embargo, los datos de este trabajo pueden verse como series temporales de temperatura y humedad, pero también se puede considerar el procedimiento de curado como la replicación de un patrón de secado a lo largo del tiempo. Usando esta aproximación, la estimación y la predicción no se basan en la similitud y la progresión de datos cercanos en el tiempo, sino en la similitud de los datos con el patrón canónico de secado usado como entrenamiento. Una red neuronal de ajuste es una buena opción para implementar esta aproximación. Esta solución se entrenará con los datos relativos a un proceso de secado completo y se testeará con el resto de los datos.

Además, utilizar una RNA de aproximación tiene la ventaja de ser más robusta frente a fallos en los sensores comparado con las RNA de series temporales, especialmente para la tarea de estimación de datos: si hay un fallo en un

sensor, en el caso de las RNA de series temporales, todas las predicciones realizadas por la RNA que usen esa medida como entrada fallarán. Por ejemplo, si una RNA usa  $n = 20$  valores de las variables de entrada para esa operación, la pérdida o fallo de una medida invalidará los datos de 20 valores de salida de la RNA. Sin embargo, si una RNA de ajuste se emplea para la estimación de datos, un fallo en el dato de entrada provocará un único fallo en el dato de salida. Esta característica es altamente recomendable en ambientes como el considerado en este trabajo donde se producen con cierta frecuencia fallos en los sensores o en la WSN.

Por lo tanto, en este trabajo se utilizó una RNA de ajuste. La arquitectura de estas redes se ajustó a tres capas de neuronas: una capa de entrada, una capa oculta y una capa de salida. El tamaño de las capas de entrada y de salida de la red se determinó por el número de entradas y salidas definidos para cada caso, por lo que se cambió a lo largo del trabajo en función del número de entradas y salidas empleados en los diferentes experimentos. El tamaño de la capa oculta dependió de la complejidad de los datos a los que se ajustó la red. Para este trabajo, el número de neuronas utilizado en la capa oculta se fijó en 20.

### Diseño del entrenamiento


Para cada una de las dos tareas, se realizaron varios experimentos con el fin de conocer el rendimiento de la RNA y estudiar la influencia de los diferentes parámetros en la precisión del dato de salida. Para la tarea de estimación de datos, los parámetros variables considerados fueron los siguientes:

- **Variables de entrada:** Diferentes experimentos se realizaron usando únicamente temperatura, humedad relativa o una combinación de las dos como variables de entrada de la RNA.
- **Número de entradas:** Varios experimentos se realizaron usando datos de un único sensor o combinando datos de dos sensores como entrada.
- **Variable de salida:** Dos tipos de test se realizaron para la estimación de datos, el primer tipo consiste en la estimación de la temperatura para un sensor y el segundo la estimación de la humedad relativa para un sensor.

Para la tarea de predicción de datos, los parámetros variables utilizados son los siguientes:

- **Horizonte temporal:** Se consideraron varios test en los que se predijeron los valores de la magnitud considerada en diferentes instantes temporales futuros: 15, 30, 150 y 300 minutos en el futuro.
- **Longitud de la secuencia de entrada:** La longitud de la secuencia de entrada utilizada para realizar la predicción varió entre diferentes experimentos.

Para evaluar el rendimiento de la RNA de manera numérica, se propuso una etapa de validación para medir la precisión del sistema. Las pruebas en la etapa de validación se realizaron con base en el esquema de la Figura 4.



**Figura 4.** Diagrama de bloques de la etapa de validación.

El error relativo entre el valor estimado y el esperado se calculó con la Ecuación (1). Dado que la temperatura esperada fue siempre mayor que 0°C (de hecho es siempre superior a 15 °C) no se produjo ningún problema con el valor del denominador. Esta misma fórmula se aplicó en los cálculos realizados con la humedad relativa.

$$e[n](\%) = \frac{T_{expected}[n] - T_{estimated}[n]}{T_{expected}[n]} \cdot 100 \quad (1)$$

## Resultados

En esta sección se presentan los resultados numéricos de los experimentos realizados con la RNA. En todos los casos, la RNA de ajuste fue entrenada con los datos de un proceso de curado completo y posteriormente testada con los datos del resto de procesos de curado. A partir de los tres sensores disponibles y las dos magnitudes medidas por cada sensor, los datos de Sensor 1 y de Sensor 2 se consideraron como potenciales entradas y los datos de Sensor 3 como la salida esperada, esto es, los datos que la RNA debe predecir y estimar.

### Estimación de datos

Los resultados obtenidos en la estimación de datos de temperatura y humedad relativa en el Sensor 3 se muestran en la Tabla 1 y la Tabla 2 y sus respectivas representaciones gráficas en la Figura 5 y la Figura 6. Esto quiere decir

que a través de este conjunto de experimentos, la RNA ha estimado la temperatura o la humedad relativa de Sensor 3 en el instante temporal  $t$  utilizando como entradas de la RNA una combinación de datos de temperatura y humedad del Sensor 1 y el Sensor 2 en ese mismo instante temporal  $t$ . En cada celda de las tablas se representa el error relativo promedio obtenido para una combinación específica de variables de entrada en una serie de 20 repeticiones diferentes del experimento.

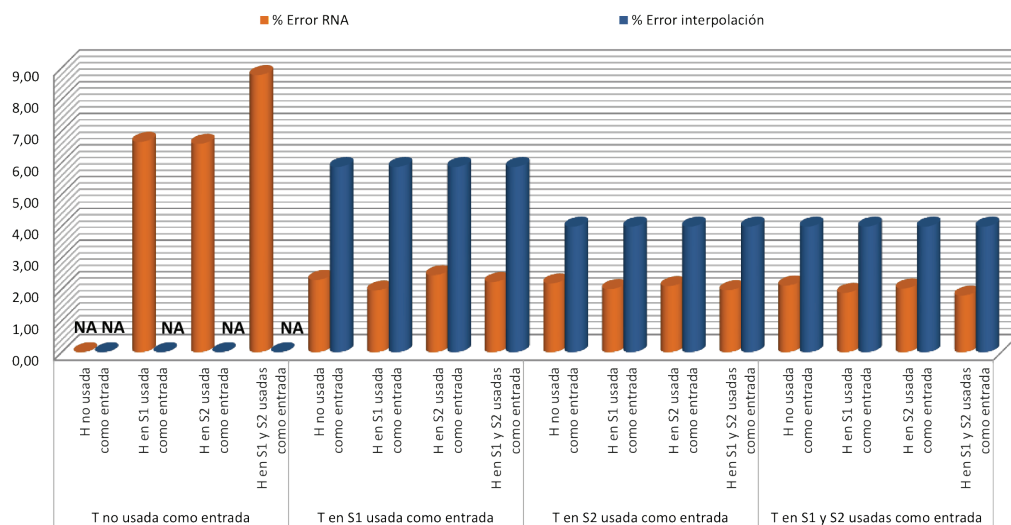
Además, para los casos en los que la entrada incluye la misma variable a ser estimada, el método de interpolación lineal directa se implementó, obteniendo también un valor estimado de salida obtenido mediante este método. Este procedimiento asume que las muestras para una variable determinada situadas en un entorno cercano a un sensor dado tomará valores similares. El error obtenido a partir de este valor interpolado se calculó como el valor medio de la señal de error, a partir de la Ecuación (1). Para cada celda de la Tabla 1 y la Tabla 2, el primer valor es el correspondiente a la estimación mediante RNA mientras que el segundo valor es el error obtenido mediante el método de interpolación. Comparando estos dos valores de error se puede apreciar la mejora que se consigue con la RNA.

Observando los resultados es sencillo apreciar en la Tabla 1 y la Figura 5 que la RNA es entre dos y tres veces más precisa que el método basado en interpolación—lo que equivale a entre un 200% y un 300% de mejora—estimando la temperatura en el Sensor 3.

Otro aspecto reseñable es que los resultados no son muy buenos—errores promedios del 6% al 9%—cuando únicamente se utiliza la humedad relativa como entrada—columna izquierda de la Tabla 1—, de lo que se puede deducir que únicamente se puede hacer una estimación “grosera” de la temperatura utilizando la RNA propuesta a partir de los valores de humedad relativa. Sin embargo, pese a que la humedad relativa muestra que por sí sola no puede estimar los valores de temperatura de forma precisa, se puede apreciar que contiene información para mejorar la estimación de temperatura, puesto que los resultados

**Tabla 1.** Resultados de estimación de datos (% error RNA/% error de interpolación) para la temperatura (T) en el Sensor 3 (S3), combinando T y humedad relativa (H) en el Sensor 1 (S1) y el Sensor 2 (S2) como entrada.

Entrada T Entrada H	T no utilizada	T en S1	T en S2	T en S1 y S2
H no utilizada		2.30%/5.87%	2.19%/3.99%	2.12%/3.99%
H en S1	6.66%/NA	1.96%/5.87%	2.01%/3.99%	1.89%/3.99%
H en S2	6.60%/NA	2.45%/5.87%	2.10%/3.99%	2.03%/3.99%
H en S1 y S2	8.77%/NA	2.23%/5.87%	1.97%/3.99%	1.80%/3.99%



**Figura 5.** Resultados de estimación de datos (% error RNA/% error de interpolación) para la temperatura (T) en el Sensor 3 (S3), combinando T y humedad relativa (H) en el Sensor 1 (S1) y el Sensor 2 (S2) como entrada.

al combinar la temperatura y humedad de los sensores de entrada son por lo general mejores que si se usa únicamente la temperatura como variable de entrada.

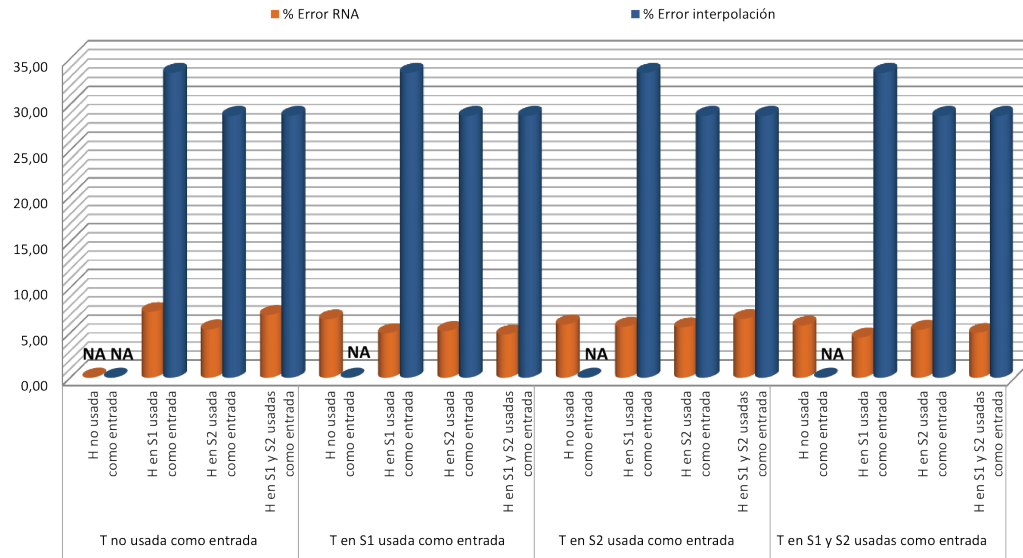
Observando la Tabla 2 y la Figura 6 es obvio que es más difícil estimar la humedad relativa que la temperatura. Los mejores resultados corresponden a un error en torno al 5%, que es el doble del mejor error obtenido para la estimación de la temperatura. Sin embargo, también es claro que se puede obtener una estimación aceptable –error medio inferior al 6%– de la humedad relativa utilizando únicamente la temperatura como variable de entrada –fila superior de la Tabla 2–, y que el uso de una RNA para este caso mejora claramente los resultados obtenidos mediante el método de interpolación, mostrando errores 6 veces menores –errores en torno al 5% frente a errores en torno al 30%–. La RNA que combina entradas de temperatura y humedad obtiene, al igual que para el caso anterior, los mejores resultados.

Como ejemplo, en la Figura 7 se muestran los resultados obtenidos en un experimento en el que se estimó la tem-

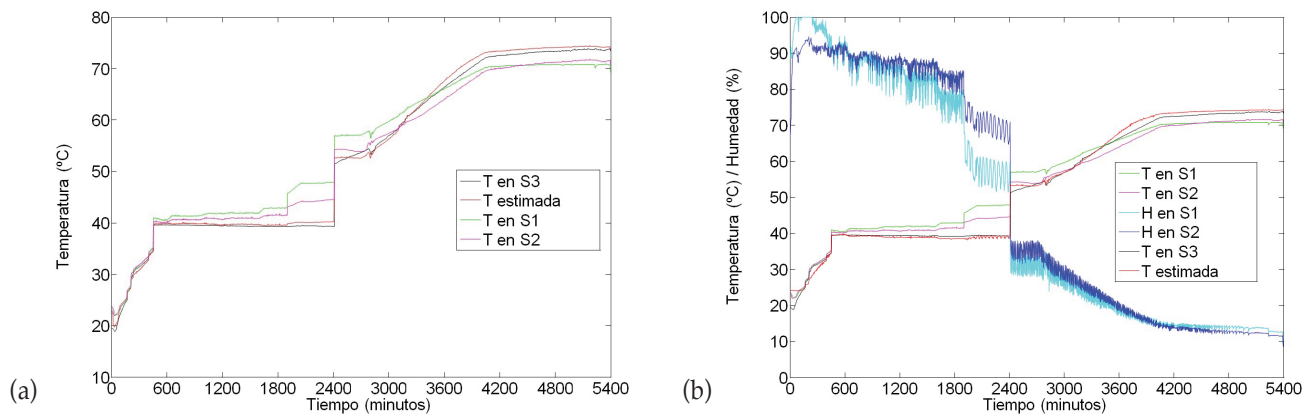
peratura en el Sensor 3 utilizando la RNA. Para ello, en la Figura 7.(a) se emplearon como variables de entrada la temperatura en el Sensor 1 y en el Sensor 2, mientras que en la Figura 7.(b) se emplearon como variables de entrada la temperatura y la humedad relativa, en esos mismos sensores. En la Figura 8 se muestran dos nuevos experimentos para estimar la humedad relativa en el Sensor 3 empleando la RNA: en la Figura 8 (a) se utiliza la humedad relativa mientras que en la Figura 8 (b) se emplea tanto la temperatura como la humedad relativa en el Sensor 1 y en el Sensor 2 como entradas de la red neuronal. Es sencillo apreciar en el proceso de curado empleado para estos experimentos una discontinuidad en los datos en torno al minuto 2.400 como consecuencia de un fallo en la WSN durante la adquisición de los datos. Pese a este fallo, se puede apreciar cómo la RNA de ajuste permite una estimación de los datos inmediatamente posteriores a la discontinuidad satisfactoria, lo cual no sería posible de haber utilizado una estimación de RNA basada en series temporales.

**Tabla 2.** Resultados de estimación de datos (% error RNA/% error interpolación) para la humedad relativa (H) en el Sensor 3 (S3), combinando temperatura (T) y H en el Sensor 1 (S1) y el Sensor 2 (S2) como entrada.

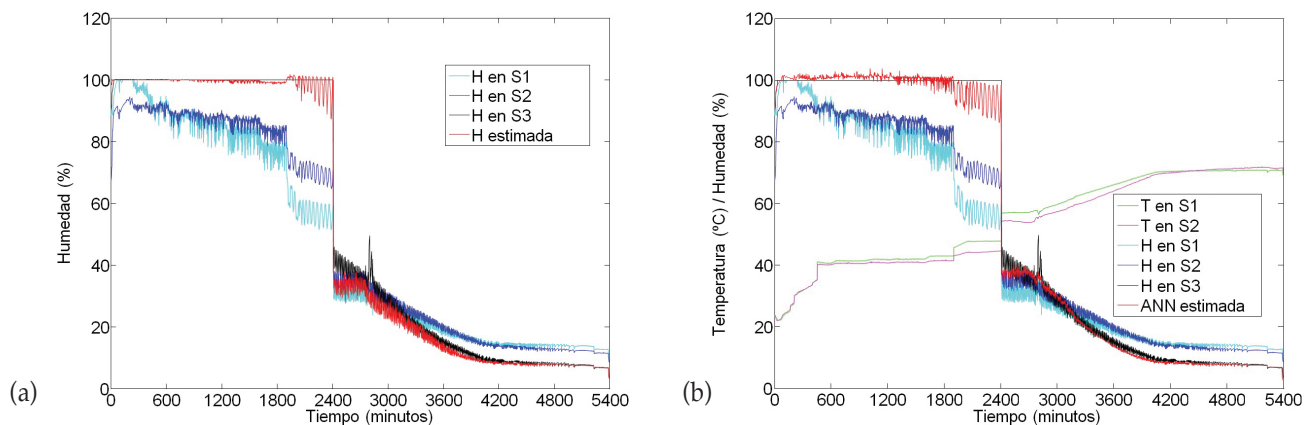
Entrada T Entrada H	T no utilizada	T en S1	T en S2	T en S1 y S2
<b>H no utilizada</b>		6.48%/NA	5.92%/NA	5.78%/NA
<b>H en S1</b>	7.30%/33.43%	4.95%/33.43%	5.66%/33.43%	4.46%/33.43%
<b>H en S2</b>	5.36%/28.72%	5.19%/28.72%	5.59%/28.72%	5.32%/28.72%
<b>H en S1 y S2</b>	6.97%/28.72%	4.80%/28.72%	6.51%/28.72%	4.98%/28.72%



**Figura 6.** Resultados de estimación de datos (% error RNA/% error de interpolación) para la humedad relativa (H) en el Sensor 3 (S3), combinando temperatura (T) y H en el Sensor 1 (S1) y el Sensor 2 (S2) como entrada.



**Figura 7.** Ejemplo de estimación de la temperatura (T) del Sensor 3 (S3) mediante RNA para un proceso de curado utilizando como entrada las señales del Sensor 1 (S1) y del Sensor 2 (S2). (a) Se utiliza como entrada únicamente T. (b) Para la entrada se utiliza tanto T como la humedad relativa (H).



**Figura 8.** Ejemplo de estimación de la humedad relativa (H) del Sensor 3 (S3) mediante RNA para un proceso de curado utilizando como entrada las señales del Sensor 1 (S1) y del Sensor 2 (S2). (a) Se utiliza como entrada únicamente H. (b) Para la entrada se utiliza tanto H como la temperatura (T).

### Predicción de datos

Los resultados obtenidos en la predicción de datos de temperatura en el Sensor 1 utilizando los valores de temperatura de este mismo sensor en el pasado se muestran en la Tabla 3 y en su respectiva representación gráfica de la Figura 9. En dicha tabla se han considerado diferentes longitudes de la secuencia de entrada –la cual contiene valores entre  $t$  y  $t-length\ of\ sequence-1$ – y diferentes valores del horizonte de predicción –el valor a predecir corresponde al instante  $t + time\ horizon$ –. En cada celda de la tabla se representa el error relativo promedio obtenido en 20 repeticiones diferentes del experimento. Además, al igual que en el apartado de estimación, se implementó un método de interpolación para realizar la misma predicción y poder servir como referencia para analizar el comportamiento de la RNA.

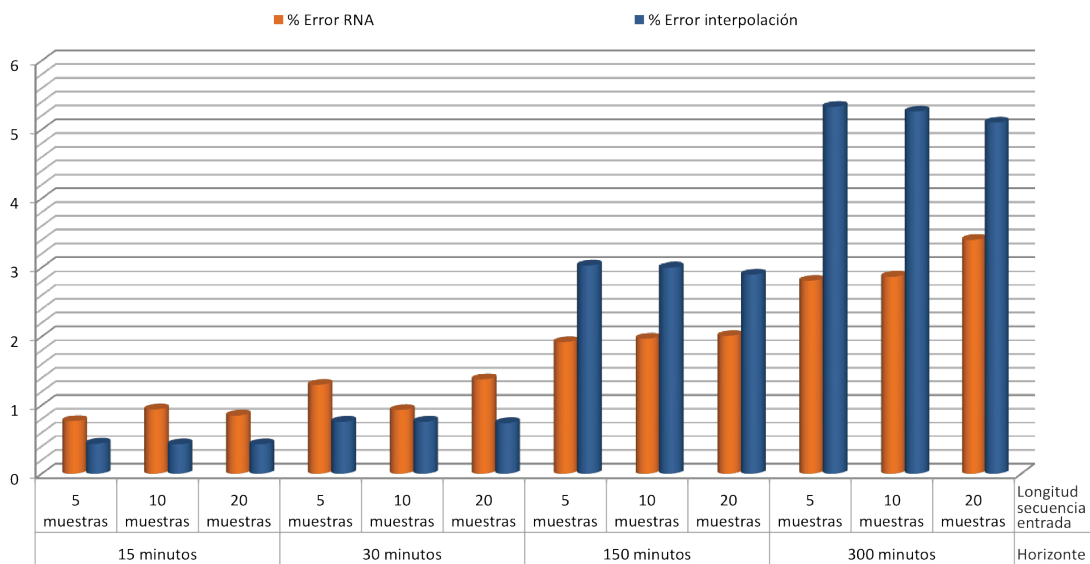
Al analizar los resultados mostrados se puede ver que el método de interpolación obtiene mejores resultados que la

RNA cuando el horizonte de predicción es corto, pese a que los errores obtenidos con la RNA son también muy pequeños. Esto se debe a que la variación de la temperatura es relativamente lenta, por lo que los valores pasados recientes son generalmente válidos para realizar una buena predicción mediante la interpolación. Sin embargo, a medida que el horizonte de predicción aumenta los resultados del método basado en interpolación empeoran rápidamente, de modo que los errores obtenidos con el método basado en RNA son menores que los sucedidos con el método basado en interpolación

Estos resultados también muestran que incrementar la longitud de la secuencia de entrada puede llegar a distorsionar la predicción, demostrando que aumentar el volumen de datos que se proporciona a la RNA no siempre garantiza mejores resultados.

**Tabla 3.** Resultados de predicción de datos (% error RNA/% error de interpolación) para la temperatura del Sensor 1 utilizando la temperatura en el Sensor 1 como entrada.

Horizonte temporal Longitud de la secuencia de entrada	15 minutos	30 minutos	150 minutos	300 minutos
5 muestras	0.77%/0.44%	1.30%/0.76%	1.92%/3.03%	2.81%/5.33%
10 muestras	0.94%/0.43%	0.93%/0.76%	1.97%/3.00%	2.87%/5.26%
20 muestras	0.85%/0.43%	1.38%/0.74%	2.01%/2.90%	3.40%/5.10%



**Figura 9.** Resultados de predicción de datos (% error RNA/% error de interpolación) para la temperatura del Sensor 1 utilizando la temperatura en el Sensor 1 como entrada.



## Combinación de estimación y predicción de datos

La Tabla 4 y la Figura 10 muestran los resultados de un experimento en el que se combinaron las operaciones de estimación y de predicción de datos. En este experimento se predijo la temperatura del Sensor 3 en el instante temporal  $t + \text{time horizon}$  como función de la temperatura en el Sensor 1. Este test se realizó para mostrar que es posible implementar una RNA que cumpla ambas tareas al mismo tiempo, mostrando de nuevo buenos resultados comparado con el método de interpolación.

## Discusión

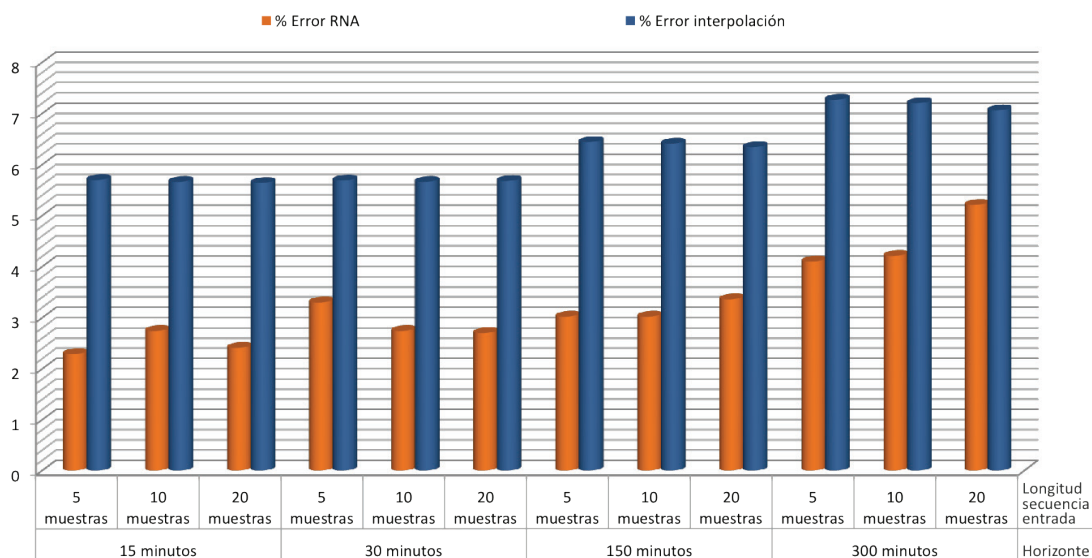
A la luz de los resultados, es sencillo darse cuenta que el error obtenido en las tareas de estimación y predicción se reduce mediante el uso de la RNA. Por ejemplo, si se pierden las lecturas de temperatura de un determinado sensor, éstas se podrían estimar a partir de las medidas de otros sensores situados en una posición cercana al primero, con un error en torno al 6%, que es más que suficiente para

muchas aplicaciones. Además, si tenemos información de temperatura de otros sensores para realizar esta estimación, la RNA es capaz de ser entre dos y tres veces más precisa que un método de interpolación equivalente. Esta diferencia es mayor en el caso de la estimación de la humedad relativa, puesto que la RNA ofrece estimaciones con un error en torno al 5%, que es entre 5 y 6 veces menor que el error del método de interpolación equivalente.

La tarea de predicción es un poco más compleja, ya que dependiendo de las condiciones de la estimación las prestaciones del método basado en RNA puede variar ostensiblemente comparado con el método basado en interpolación. Dado que las magnitudes monitorizadas varían de manera lenta hay que tener en cuenta que para horizontes de predicción pequeños es mejor la predicción basada en interpolación. Sin embargo se ha visto que a medida que el horizonte de predicción aumenta, la RNA es capaz de obtener resultados más precisos que el método de interpolación.

**Tabla 4.** Resultados de predicción de datos (% error RNA/% error de interpolación) para la temperatura del Sensor 3 utilizando la temperatura en el Sensor 1 como entrada.

Horizonte temporal Longitud de la secuencia de entrada	15 minutos	30 minutos	150 minutos	300 minutos
5 muestras	2.29%/5.70%	3.30%/5.69%	3.02%/6.44%	4.10%/7.27%
10 muestras	2.74%/5.66%	2.74%/5.66%	3.02%/6.41%	4.21%/7.20%
20 muestras	2.41%/5.64%	2.70%/5.68%	3.36%/6.34%	5.21%/7.06%



**Figura 10.** Resultados de predicción de datos (% error RNA/% error de interpolación) para la temperatura del Sensor 3 utilizando la temperatura en el Sensor 1 como entrada.

Las estimaciones que proporciona el sistema propuesto se podrían utilizar para detectar fallos en sensores y recuperar las mediciones erróneas provocadas por dichos fallos. Los fallos en los sensores se podrían detectar comparando la diferencia absoluta entre la estimación y el valor real con un valor umbral previamente elegido. De este modo, si la diferencia absoluta es mayor que el umbral se puede considerar que se ha producido un fallo. En este caso, y hasta que el fallo del sensor se haya solucionado, las medidas de este sensor se podrían reemplazar por las medidas estimadas por la RNA usando las medidas del resto de sensores como valores de entrada. Además, esta aplicación de recuperación de datos se podría usar también para recuperar datos cuando se producen otros tipos de fallos en los sensores, tales como la corrupción o la pérdida de la señal del sensor, que son dos problemas típicos en WSN (Tamboli y Younis 2010; Kwong *et al.*, 2012).

Otra aplicación para el sistema de estimación propuesto sería la optimización en el diseño de sistemas de adquisición de datos. Para ello, se debería desplegar un conjunto de sensores en los puntos de interés del sistema a monitorizar y adquirir los datos de estos sensores durante un tiempo suficientemente representativo. Después de ello, los métodos de estimación basados en RNA propuestos servirían para descartar los sensores cuyas medidas pueden ser estimadas de manera más precisa con el resto de sensores desplegados como entrada. Una ventaja de un sistema diseñado de este modo sería el ahorro económico debido a la supresión de los sensores cuya medida se puede estimar con el resto de sensores. Otra ventaja sería la posibilidad de estimar las medidas en puntos peligrosos o sujetos a condiciones hostiles de funcionamiento. En estos puntos los sensores empleados para la adquisición de la variable de interés deberán ser más robustos ante los fallos o la degradación del ambiente, pero con el método propuesto se podría intentar suprimir este sensor y estimar el valor de las variables que adquiriría con otros sensores situados en localizaciones más seguras o con mejores condiciones ambientales.

Los métodos de predicción y estimación propuestos también pueden ser utilizados para modelar procesos. Los modelos establecen relaciones entre las variables que caracterizan un proceso y son capaces de predecir el valor de estas variables en el futuro, y han sido utilizados en procesos de secado de productos agrícolas en varios trabajos de la literatura científica (Papantoniou y Coonick 1997; Toğrul 2006; Movagharnejad y Nikzad 2007). Estos modelos en ocasiones se desarrollan como parte de algoritmos de control predictivo basados en modelos, que son algoritmos que tienen en cuenta las predicciones futuras del estado del proceso a la hora de decidir el estado de los actuadores

controlados. Algoritmos de control predictivo que utilizan una RNA para realizar la predicción en el algoritmo se han propuesto en la literatura científica aplicada al control de aplicaciones industriales (Benne *et al.*, 2000; Al Seyab y Cao 2008; Damour *et al.*, 2010), de la navegación aérea (Akpan and Hassapis 2011) o de procesos en laboratorios (Song *et al.*, 2007).

Otra aplicación para los métodos de predicción de datos sería la mejora de los sistemas de alarma. Un problema típico de muchos sistemas de alarma es el alto número de falsos positivos y falsos negativos que se producen en el sistema. Una causa de este problema es que los sistemas únicamente tienen en cuenta información en tiempo real o información del presente y del pasado, de modo que la incorporación a este tipo de sistemas de predicciones sobre el futuro estado del sistema podría mejorar la precisión del sistema de alarmas (Zhou *et al.*, 2011).

Por último, los métodos de predicción propuestos podrían ser fácilmente utilizados para anticipar las decisiones a tomar durante el proceso de secado. El operario encargado de controlar el proceso podría ver una predicción del estado de las variables del secadero de tabaco con base en el estado actual y pasado de las mismas, y a la decisión de control que se tome en el instante actual. De este modo el operario podría tomar la decisión más apropiada, y mejorar los resultados del proceso derivados de la toma de decisiones humanas. Esta aplicación sería un ejemplo particular de algoritmo de control basado en modelo, con un control supervisado del proceso por parte de la persona responsable del mismo.

## Conclusiones

El curado de tabaco ha sido tradicionalmente un proceso artesanal controlado de forma manual, confiando en el saber hacer de los expertos y considerándose prácticamente un arte. Sin embargo, al igual que en muchas otras áreas de la agricultura, han aparecido nuevas tecnologías que permiten controlar el proceso de manera sencilla, aumentar de manera ostensible el rendimiento del proceso, mejorar los resultados y disminuir los costes al mismo tiempo. Más específicamente, la introducción de WSN y la automatización mediante sistemas inteligentes es una tendencia clara en la agricultura, como se puede observar en el estado del arte de los procesos de secado. El rendimiento de estos sistemas depende en gran medida de la precisión de los datos que proporciona la red de sensores, de modo que si esta precisión mejora también lo harán los resultados del sistema.

El trabajo presentado en este artículo ha mostrado que con una RNA de ajuste es posible estimar de manera precisa los valores de diferentes variables del proceso empleadas

en el control de dicho proceso en diferentes puntos espaciales. Los resultados numéricos obtenidos presentan errores muy pequeños, alcanzando valores inferiores del 2% que son rangos de error comparables con la precisión del tipo de sensores utilizado.

Además, el sistema propuesto es capaz de predecir el valor de las variables consideradas en el futuro con diferentes horizontes de predicción. Para horizontes de predicción pequeños, el error promedio obtenido con una interpolación es similar al conseguido con el sistema basado en RNA, mientras que para horizontes de predicción mayores el error de la RNA es menor que el obtenido mediante interpolación.

Por último, es interesante mencionar que tanto la capacidad de estimar como la de predecir el valor de una variable que tiene el sistema propuesto son potencialmente útiles para mejorar el desempeño de los sistemas automáticos de control del curado de tabaco y al mismo tiempo reducir los costes del proceso, aumentando la cantidad y la calidad de datos disponibles en el sistema.

## Agradecimientos

Este trabajo fue parcialmente financiado por dos proyectos. El primero, titulado "Mejora de la competitividad del sector del tabaco en Extremadura: nuevos procesos y productos", fue financiado por el Centro para el Desarrollo Tecnológico Industrial (CDTI) bajo el proyecto IDI-20100986. El segundo fue financiado por el Plan Regional de Investigación 2010, de la Junta de Castilla y León (España), con el proyecto VA034A10-2.

El trabajo del primer autor también fue posible gracias a la beca de Formación de Personal Investigador (FPI). Este programa está financiado por la Universidad de Valladolid y cofinanciado por el Banco Santander. Además, los experimentos fueron parcialmente financiados por otra beca obtenida por el primer autor en la competición denominada "¿Investigamos? 2011" a través de un proyecto titulado "Desarrollo de un sistema SCADA para el control del curado del tabaco". Esta competición fue organizada por el Centro Tecnológico Agrario y Agroalimentario ITAGRA.

## Referencias

AKPAN, V. A. and HASSAPIS, G. D. Nonlinear model identification and adaptive model predictive control using neural networks. *ISA Transactions*50(2). 2011; p. 177-194.

AL SEYAB, R. K. and CAO, Y. Nonlinear system identification for predictive control using continuous time recurrent neural networks and automatic differentiation. *Journal of Process Control*18(6).2008; p. 568-581.

BANGA, J. R. AND SINGH, R. PAUL. Optimization of air drying of foods. *Journal of Food Engineering*23(2).(1994); p. 189-211.

BENNE, M., B. ; GRONDIN-PEREZ, J. CHABRIAT, P. and HERVÉ, P.. Artificial neural networks for modelling and predictive control of an industrial evaporation process. *Journal of Food Engineering*46(4).(2000); p. 227-234.

DAMOUR, C.; BENNE, M.; GRONDIN-PEREZ, B. and CHABRIAT, J.-P. Nonlinear predictive control based on artificial neural network model for industrial crystallization. *Journal of Food Engineering*99(2).(2010); p. 225-231.

DORFFNER, G. Neural Networks for Time Series Processing. *Neural Network World*6(4).(1996); p. 447-468.

FROST, A. R.; SCHOFIELD, C. P.; BEAULAH, S. A.; MOTTRAM, T. T.; LINES, J. A. and WATHES, C. M. A review of livestock monitoring and the need for integrated systems. *Computers and Electronics in Agriculture*17(2).(1997); 139-159.

HAWKS, S. N.; COLLINS, W. K. ; CARBONELL, H. P. AND MARTÍNEZ, E. C. Tabaco flue-cured: principios básicos de su cultivo y curado, Ministerio de Agricultura, Pesca y Alimentación. 1986.

HILL, T., M. O'CONNOR and W. REMUS. "Neural Network Models for Time Series Forecasts." *Management Science*42(7): 1082-1092.

HOLLAND, E. P., J. F. BURROW, C. DYTAM and J. N. AEGERTER. Modelling with uncertainty: Introducing a probabilistic framework to predict animal population dynamics. *Ecological Modelling*220(9-10).(2009) p.1203-1217.

KWONG, K. H., WU, T.-T.; GOH, H. G.; SASLOGLOU, K.; STEPHEN, B.; GLOVER, L.; SHEN, C.; DU, W.; MICHIE, C. and ANDONOVIC, I. Practical considerations for wireless sensor networks in cattle monitoring applications. *Computers and Electronics in Agriculture*vol 81.(2012); p. 33-44.

LI, Z., G. S. V. RAGHAVAN and N. WANG. Carrot volatiles monitoring and control in microwave drying. *LWT - Food Science and Technology*43(2).(2010); p.291-297.

LI, Z., G. S. V. RAGHAVAN, N. WANG and Y. GARIEPY. Real-time, volatile-detection-assisted control for microwave drying." *Computers and Electronics in Agriculture*69(2).(2009); p. 177-184.

LI, Z.; VIJAYA RAGHAVAN, G. S. AND WANG, N. APPLE volatiles monitoring and control in microwave drying. *LWT - Food Science and Technology*43(4).(2010); p. 684-689.

MOVAGHARNEJAD, K. and NIKZAD, M. MODELING of tomato drying using artificial neural network. *Computers and Electronics in Agriculture*59(1-2).(2007); p. 78-85.

NATIONS., F. A. O. O. T. U. and T. H. P. S. Commodities Trade Division Agriculture Organization of the United Nations. Raw Materials. Issues in the global tobacco economy: selected case studies. Rome, Raw Materials, Tropical and Horticultural [sic] Products Service, Commodities and Trade Division, Food and Agricultural Organization of the United Nations. 2003

PAPANTONIOU, A. and COONICK, A. Fuzzy logic control of a unified power flow controller for wind farm applications. *Power Electronics for Renewable Energy (Digest No: 1997/170), IEE Colloquium on.*

RECKNAGEL, F.; FRENCH, M. ; HARKONEN, P. and YABUNAKA, K.-I. Artificial neural network approach for modelling and prediction of algal blooms. *Ecological Modelling*96(1-3).(1997); p. 11-28.

- SINGH, K. P., BASANT, A.; MALIK, A. and JAIN, G. Artificial neural network modeling of the river water quality—A case study. *Ecological Modelling* 220(6). (2009); p. 888-895.
- SMITH, B. A.; HOOGENBOOM, G. AND MCCLENDON, R. W.. Artificial neural networks for automated year-round temperature prediction. *Computers and Electronics in Agriculture* 68(1). (2009); p. 52-61.
- SONG, Y., Z. CHEN and YUAN. Neural Network Nonlinear Predictive Control Based on Tent-map Chaos Optimization. *Chinese Journal of Chemical Engineering* 15(4). (2007); p. 539-544.
- TAMBOLI, N. and YOUNIS, M. Coverage-aware connectivity restoration in mobile sensor networks. *Journal of Network and Computer Applications* 33(4). 2010; 363-374.
- TOĞRUL, H.. Suitable drying model for infrared drying of carrot. *Journal of Food Engineering* 77(3). (2006); p. 610-619.
- YLINIEMI, L. Advanced Control of a Rotary Dryer. Department of Process Engineering. Oulu, Finland, University of Oulu: 114. 1999.
- YLINIEMI, L., J. KOSKINEN and LEIVISKA, K.. Advanced control of a rotary dryer. Oxford, Pergamon Press Ltd.
- YUE, T.-X.; JORGENSEN, S. E. and G. R. LAROCQUE (2011). Progress in global ecological modelling. *Ecological Modelling* 222(14). (1999); p. 2172-2177.
- ZHOU, H. F., Y. Q. Ni and KO, J. M.. Structural damage alarming using auto-associative neural network technique: Exploration of environment-tolerant capacity and setup of alarming threshold." *Mechanical Systems and Signal Processing* 25(5). (2011); p. 508-1526.