

**Boffa, Guillermo ; Casiello, Francisco ; Galaretto, Oscar;
Fariás, Ana María ; Herrera, Luis Alberto**

*Secado industrial de granos de origen agrícola:
alternativas para el control de procesos de
secado*

Energeia, Año 10, N° 10, 2012

Este documento está disponible en la Biblioteca Digital de la Universidad Católica Argentina, repositorio institucional desarrollado por la Biblioteca Central "San Benito Abad". Su objetivo es difundir y preservar la producción intelectual de la Institución.

La Biblioteca posee la autorización del autor para su divulgación en línea.

Cómo citar el documento:

Boffa, G. et al. Secado industrial de granos de origen agrícola : alternativas para el control de procesos de secado [en línea]. *Energeia*, 10(10), 2012. Disponible en:
<http://bibliotecadigital.uca.edu.ar/repositorio/revistas/secado-industrial-alternativas-control.pdf> [Fecha de consulta:
.....]

Secado industrial de granos de origen agrícola: Alternativas para el control de procesos de secado.

Boffa, Guillermo; Casiello, Francisco; Galaretto, Oscar; Farías, Ana María; Herrera, Luis Alberto

Resumen: En el presente trabajo se revisa el estado del conocimiento con relación al control de secado de granos y se discute la aplicación de redes neuronales para el control de secadoras industriales. El trabajo revisa primero los conceptos generales de secado de granos y se especifica el problema de control, discutiéndose la noción de observación de estado en los procesos, especializándose en el observador clásico de Kalman y su extensión a las redes neuronales. Finalmente se discute la aplicación de control de mínima varianza para el caso de interés.

Palabras Claves: Granos agrícolas - modelos de secado - control de procesos - redes neuronales

1. El control de procesos de secado de granos

El problema de control de procesos de secado de granos es de gran importancia en la optimización del consumo energético de los mismos y existe una gran cantidad de trabajos dedicados al estudio del mismo¹. En términos generales las estrategias de control pueden clasificarse en cuatro grandes grupos²; 1) Los que emplean condiciones de operación predeterminadas y terminan la operación de secado luego de un tiempo dado; 2) los que usan condiciones de operación fijas y emplean sensores para determinar el tiempo de finalización, logrando de esa manera compensar ciertas perturbaciones (tales como diferentes condiciones de humedad del grano de entrada); 3) los que siguen una trayectoria de estado predefinida, empleando controles convencionales del tipo proporcional más integral y 4) los que sistemáticamente recalculan una trayectoria óptima que debe seguirse desde el estado inicial al final, basados en predicciones que pueden ser obtenidas por algún tipo de modelo del proceso.

1.1 Primera especificación del problema

Evidentemente la clasificación anterior supone una complejidad en aumento desde el primer caso en el que la operación se hace totalmente a “lazo abierto”, incorporándose alguna realimentación en el segundo, con una mayor automatización en el tercer caso y con una sofisticación todavía más importante en el tercer caso. En cualquier caso el problema de control apunta a asegurar una cierta humedad del grano, generalmente especificada por medio del “cociente de humedad” MR , que se define como:

$$MR = \frac{M - M_e}{M_o - M_e}$$

Donde

M = el contenido de humedad en un instante t , en porcentaje de “base seca”.

M_o = el contenido inicial de humedad, en porcentaje de “base seca”.

M_e = el contenido de humedad de equilibrio, en porcentaje de base seca.

¹ - Thompson, T. L., Peart, R. M. y Foster, G. H., “Mathematica Simulation of Corn Drying – A New Model”, Transactions of the American Society of Agricultural Engineers, Vol. 11, N° 4, 1968, pp. 582-586

- Trelea, I. C., Trystram, G. y Courtois, F., “Optimal Constrained Non-linear Control of Batch Processes: Application to Corn Drying”, Journal of Food Engineering, N° 31, 1997, pp. 403-421.

- Abdel-Jabba, N. M., Jumah, R. Y. y Al-Haj Ali, M. Q., “State estimation and state feedback control for continuous fluidized bed dryers”, Journal of Food Engineering, 2004.

² Trelea, I. C., et al., ob. cit., p. 404.

Sin embargo justamente este cociente de humedad que caracteriza la humedad del grano, es una variable de estado que, junto con otras variables importantes tal como la temperatura del mismo, así como sus distribuciones dentro del grano, no son directamente accesibles. Por su parte hay otras variables que son más fácilmente accesibles, tales como la temperatura y la humedad tanto del aire de entrada como del aire de salida en el proceso de secado.

En particular variables tales como la temperatura y el caudal del aire de entrada pueden emplearse como variables de control, junto con la velocidad de flujo del grano que determina el tiempo de tránsito del mismo en la secadora. De esta manera queda constituida una primera separación entre las variables de estado, dentro de ellas las que se pueden medir en forma directa y las que no, y las de control.

1.2 Modelos clásicos empleados en el secado de granos

Para modelar la cinética de secado de granos se emplean varios tipos de modelos. Típicamente pueden clasificarse dentro de tres grandes grupos³:

1) Modelos basados en la descripción de los mecanismos de difusión. Estos modelos tienen la ventaja de que el número de parámetros que deben ser ajustados en forma experimental es bajo. El problema radica en que el coeficiente de difusión en general no es constante y deben considerarse los acoplamientos propios de la transferencia de masa y de calor.

2) Modelos basados en la descripción del comportamiento macroscópico, empleando, por ejemplo las leyes de Fick y de Fourier para modelar la transferencia de calor y de masa entre el grano y el aire que lo rodea.

3) Representaciones empíricas que no realizan suposiciones con relación a los mecanismos por los cuales se produce el secado. Agregaremos a esta clasificación

4) Los modelos “mixtos” que emplean una descripción microscópica acompañada de una macroscópica y que se complementan por medio de “observadores” que no modelan el proceso de secado, sino que se limitan a estimar variables de estado observables a los efectos de acompañar un sistema de control de humedad. Dentro de la última alternativa inscribiremos el tipo de modelo que nos interesa para este estudio: el de las redes neuronales adaptivas. Pero antes necesitamos revisar el concepto de “observador”.

1.3 Observadores

Se entiende por “observador” a un algoritmo capaz de estimar una variable de estado que no es medible en forma directa, por medio de otras variables de estado y de control que sí lo son.

1.3.1 El clásico observador de Kalman

Si los procesos bajo estudio se modelan de una manera relativamente simple (ver por ejemplo Abdel-Jabba et al.⁴), mediante un sistema de ecuaciones diferenciales lineales de primer orden, en este caso es bien sabido que es posible encontrar un observador lineal óptimo de Kalman⁵ que estima las variables observables⁶ de estado en función de las variables que pueden medirse, incluyendo las entradas de control. Sin embargo los modelos anteriores en general no describen adecuadamente la dinámica de secado en secadoras industriales, cosa que se requiere como condición para que el observador pueda ofrecer las variables de estado que no son medibles en forma directa⁷.

³ Trelea et al, ob. cit., p. 409.

⁴ Abdel-Jabba, N. M. et al, ob. cit.

⁵ Kalman, R., “A new Approach to linear filtering and prediction problems, Transactions of the ASME, Journal of Basic Engineering, 82, 35 – 45.

⁶ Recuérdese que en este caso la noción de “observabilidad” o “variable observable” es, justamente, la de aquella que puede estimarse por medio de variables directamente medibles.

⁷ Fohr, J. P., Arnaud, G., Ali Mohamed, A y Ben Mossa, H, “Validity of drying kinetics”, Sixth International Drying Symposium, Versailles, France, 1988.

1.3.2 Observadores de redes neuronales

Contemporáneamente es posible emplear las “redes neuronales artificiales” (RNA) como observadores de variables de estado. Si bien existen muchos tipos de redes neuronales, en términos generales éstas son algoritmos capaces de representar una aplicación $f: R^n \rightarrow R^m$ “aprendiendo” a mapear los puntos de R^n en los correspondientes de R^m por medio de un proceso previo de “aprendizaje” en el que ciertos puntos ya conocidos de dicho mapa son presentados como “patrones” y llevados a un algoritmo de optimización, de modo que el “mapa” resultante sea de mínimo error cuadrático. (redes de backpropagation). Aunque tal definición parecería poder adaptarse también a una “regresión no lineal”, la diferencia es que en el caso de las RNA no es necesaria ninguna especificación paramétrica del mapa de aplicación, sino que el mismo es construido por la misma red.

1.3.2.1 Estructura básica de las RNA

La figura 1 ilustra una red neuronal. La misma consta de tres capas, la primera con cuatro neuronas artificiales, la segunda o intermedia con tres y la tercera capa también con cuatro neuronas. Además tiene dos entradas, x_1 y x_2 y una salida y .

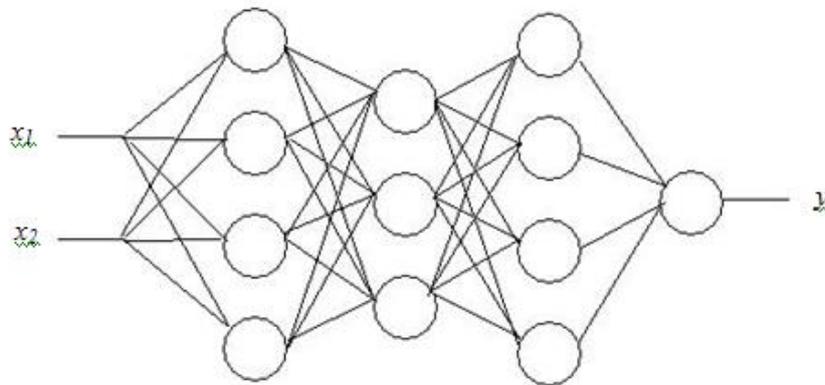


Figura 1. Esquema básico de una red neuronal (Elaboración propia)

Es bien conocido⁸ que es posible “entrenar” esta red para que aprenda el “mapa” que relaciona el espacio de variables de entrada con los valores (escalares, en este caso) de la variable de salida. Las redes neuronales adaptivas, pueden considerarse como mecanismos de aproximación de mapas de $R^n \rightarrow R^m$, donde n y m son las dimensiones de los espacios de salida y de llegada. La intención de los puntos que siguen es bosquejar la aplicación de redes neuronales adaptivas para la observación de variables no medibles en forma directa.

La figura 2 ilustra un diagrama básico de una secadora de la que se obtienen datos de caudal, temperatura y humedad de aire de entrada y salida. La dificultad radica en conocer el estado de humedad del grano que se encuentra en proceso de secado. De allí la necesidad de un observador que pueda estimar dicha cantidad en función de otros parámetros fácilmente medibles.

⁸ I. Farkas; P. Reményi; A. Biró, **Modelling aspects of grain drying with a neural network**. *Computers and Electronics in Agriculture*, vol. 29 pages 99 -113. Elsevier Science, 2000.

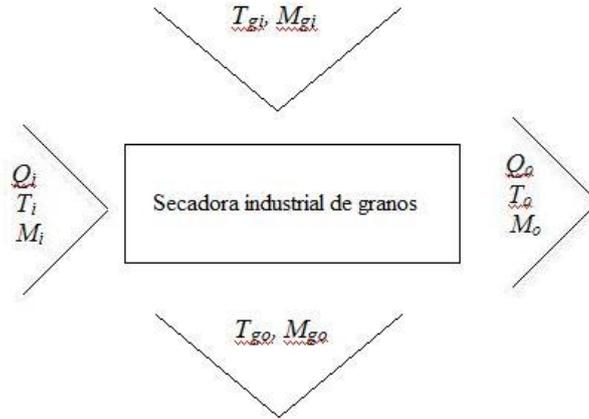


Figura 2 – Esquema básico de una secadora industrial de granos. Q_i , T_i y M_i son el caudal, la temperatura y la humedad del aire de entrada. Q_o , T_o , y M_o , son los del aire de salida. T_{gi} , M_{gi} y T_{go} y M_{go} son las temperaturas y humedades de los granos a la entrada y a la salida de la secadora. (Elaboración propia)

1.3.2.2 Arquitectura básica de una red neuronal de backpropagation para la estimación de la humedad del grano

En una primera aproximación, que será complejizada más adelante en este trabajo, supondremos que el proceso de secado puede caracterizarse por medio de una ecuación diferencial del primer orden del siguiente tipo:

$$\frac{dMR}{dt} = k MR(t) \quad MR(t = 0) = MR_0$$

Acá MR es el “cociente de humedad” definido anteriormente y k es un parámetro de secado que depende de las condiciones de operación Q_i , T_i y M_i y Q_o , T_o , y M_o . Bajo condiciones fijas, suponiendo entonces que k es constante, la humedad del grano evoluciona temporalmente como $MR(MR_0, t) = MR_0 e^{kt}$.

De esta manera la función de humedad del grano se representa por una mapa escalar bidimensional como el que se representa en la figura 3, de modo que la misma puede establecerse si se conocen MR_0 y t .

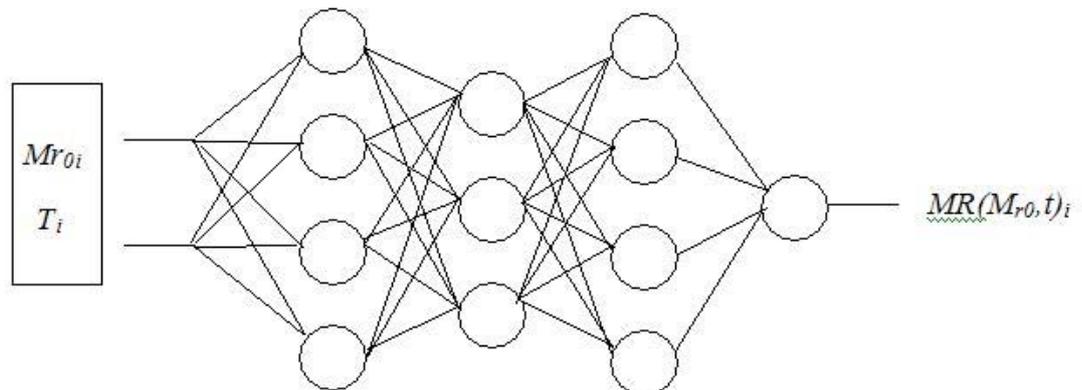


Figura 3. Estructura básica de una red neuronal para el reconocimiento de patrones de humedad en secadoras de granos. (Elaboración propia)

Ahora bien, considérense la dupla (MR_{0i}, t_i) , $i=1, \dots, n$, donde n es el número de patrones de entrenamiento de la red. Denomínese “patrón” a cada dupla. Entonces puede pensarse que, en correspondencia con cada “patrón”, existe un valor de MR_i que está dado por la solución de la ecuación diferencial anterior. Es posible entonces emplear una red de backpropagation y entrenar la misma de modo de lograr que aprenda el mapa y pueda, luego de su entrenamiento, estimar la humedad del grano conocidas, en este caso, las condiciones iniciales y el tiempo. En la figura 4 se da un esquema básico de la red.

Por consiguiente, esta red podría ser entrenada por un grupo de patrones conocidos (MR_{0i}, T_i) de los cuales se conocería la salida MR_i , de modo que la misma pudiera adaptarse y reconocer el mapa entero $MR(MR_0, t)$. De esta manera, para cualquier patrón (MR_{0i}, T_i) , no empleado en el entrenamiento, podría conocerse la humedad deseada MR_j . Y esto podría realizarse en línea de operación, para estimar la humedad del grano, a los efectos de su control.

1.3.2.3 Un modelo más realista

Como el proceso de secado transcurre mientras el grano recorre la secadora desde arriba hacia abajo es evidente que en la parte superior de la secadora, donde ingresan los granos, la humedad de los mismos será mayor que en la sección baja de la secadora, por donde egresa el grano seco. Además la distribución de humedad naturalmente depende de la posición del grano en la compleja geometría interna del dispositivo. En términos generales, podría decirse que la humedad del mismo es una función tanto de su posición en la secadora como del tiempo, es decir:

$$MR = MR(x, y, z, t)$$

donde

MR es la función “cociente de humedad” definida anteriormente. Realizaremos la suposición que, al ser la secadora de “flujo continuo”, es decir que el grano fluye de manera continua por la misma, el proceso de secado es suficientemente uniforme como para caracterizar la humedad sólo por su posición espacial en la secadora.

De esta manera:

$$MR = MR(x, y, z)$$

Bajo situaciones controladas, y de manera similar al caso anterior, pueden encontrarse un conjunto de “patrones” $(Q_i, T_i, M_i, Q_o, T_o, M_o)_k$ y, correspondientemente, el nivel de humedad $MR(x, y, z)_k$, $(k=1, \dots, n)$, donde n es el número de patrones de entrenamiento, de tal manera de identificar el mapa, más complejo ahora, que permita estimar la humedad del grano en cualquier punto de la secadora en función de parámetros de fácil medición.

2. Elementos de control

2.1. Introducción

Existen diferentes estrategias de control que han sido descritas en la literatura para el control de secadoras de granos. Ante todo la estrategia de control depende del tipo de proceso a ser controlado o, al menos, de la consideración que se haga del mismo, en especial si se considera el proceso continuo o en batch. Trelea⁹ considera la situación de secado de granos como un proceso en batch para un montaje experimental de cama delgada en la que el grano (de maíz, en este caso), permanece en la secadora hasta tanto el grano alcance la humedad promedio deseada.

Aunque el modelo de secado es demasiado ideal para una situación real, es interesante la propuesta que realiza con relación a estimar la humedad por medio de redes neuronales adaptivas con patrones que contienen información del contenido inicial de humedad del grano, la temperatura del aire de entrada, y el tiempo de exposición del grano al proceso de secado, para obtener la humedad de salida del grano. Sin embargo, si el grano se hace transitar por la secadora durante un período de tiempo dado y el grano va paulatinamente siendo secado desde el principio al fin, entonces el proceso puede considerarse más bien como continuo.

La figura 4 muestra el proceso de secado en un diagrama de control más convencional. Las variables de control son el caudal del aire de entrada (Q_i) y la temperatura del mismo (T_i). La temperatura del grano (T_{gi}), su humedad (M_{gi}) y la humedad del aire de entrada (M_i) se consideran perturbaciones y se representan como

⁹ Trelea et al., ob. cit., p. 404.

entradas adicionales. Por su parte la salida principal es la humedad del grano, (M_{go}), y se pueden observar el caudal del aire de salida (Q_o), la humedad del mismo (M_o), su temperatura (T_o) y la temperatura del grano a la salida (T_{go}).

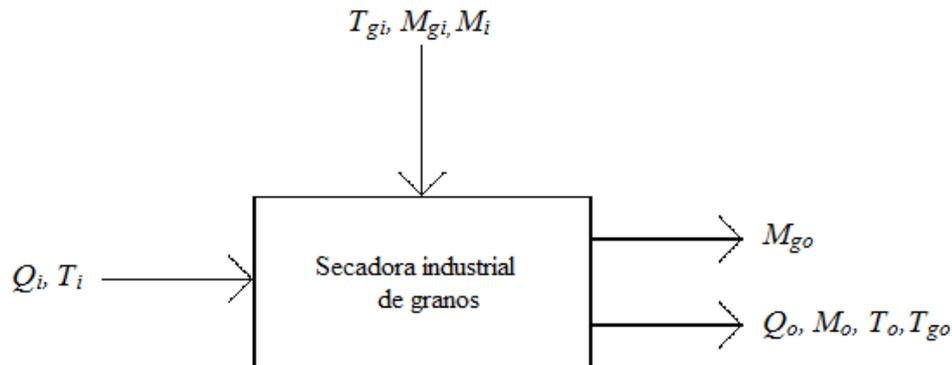


Figura 4. Proceso de secado de granos. Las designaciones se corresponden con las de la figura 2. (Elaboración propia).

Uno de los problemas radica en que la humedad de salida del grano no es fácilmente observable, de modo que, como se ha indicado anteriormente, es posible emplear un observador de redes neuronales para estimarla. La temperatura del grano es más fácil de medir.

Empleando una red neuronal que estime la humedad del grano a partir de los patrones generados por las variables de entrada y salida observables, obtenemos un diagrama tal como el que se da en la figura 4.

2.2. El control de mínima varianza

De particular interés para la situación actual es la implementación de un sistema de control de mínima varianza¹⁰. En efecto, siendo que el interés es obtener una humedad en el grano de salida lo más cercana posible al valor deseado o de referencia, entonces, es posible definir $y(t) = M_{go} - M_{goREF}$, donde M_{goREF} es la humedad deseada del grano. Notamos que $y(t)$ es una variable aleatoria, ya que es el resultado de un proceso de secado en el que están presentes las perturbaciones T_{gi}, M_{gi} y M_i más las que naturalmente surjan del movimiento del grano en la secadora. De esta manera $E[y(t)^2]$ resulta la varianza de la humedad del grano.

Si se desea realizar un control digital de mínima varianza, de modo de $\min E[y(t)^2]$, suponiendo que el proceso puede representarse, en una primera aproximación, por

$$y(t) + ay(t - 1) = u(t - 1) + e(t) + ce(t - 1)$$

entonces una primera aproximación para el diseño de un algoritmo de control¹¹ es hacer

$$u(t) = (a - c)y(t)$$

Como esto supone conocer $y(t)$, entonces este valor puede estimarse empleando la red neuronal descrita anteriormente a tales fines.

2.2.1 Elementos básicos del control de mínima varianza:

Resulta de particular interés la implementación de un sistema de control de mínima varianza, dado que necesitamos obtener una humedad en el grano de salida lo más cercana posible al valor deseado o de referencia, siguiendo este razonamiento, para determinar la ley de control de varianza mínima, recurrimos a un modelo polinomial de planta¹², donde consideramos el caso especial en que el polinomio B es estable (en este caso el sistema se denomina de fase mínima porque la función de transferencia discreta tiene todos sus

¹⁰ Astrom, K, Introduction to Stochastic Control Theory, Academic Press, New York, 1970, p. 159 y ss.

¹¹ Astrom, ob. cit, p. 161

¹² Astrom, K, Introduction to Stochastic Control Theory, Academic Press, New York, 1970, p. 158 y ss.

ceros dentro del círculo unidad). De este modo la estrategia de varianza mínima se obtiene prediciendo la salida (d) pasos más adelante y eligiendo un control que haga la predicción igual a la salida deseada.

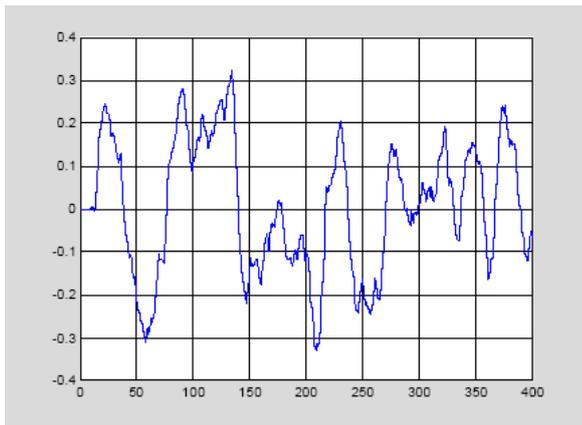


Figura 5a. Señal de Salida Y(k)

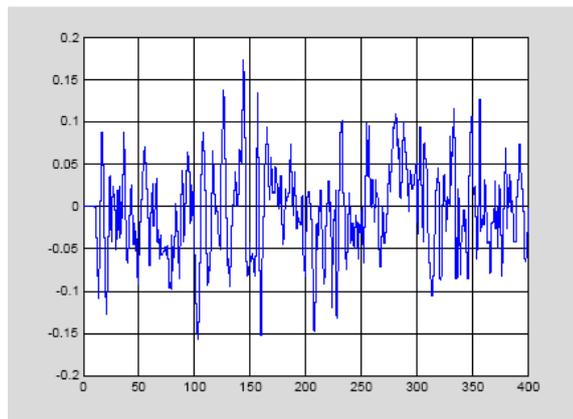


Figura 5b. Señal de Control u(k)

En las figuras anteriores (5a y 5b) vemos una simulación de la salida del sistema Y(k) y de la señal de control u(k), se advierte a simple vista la reducción de la varianza.

El problema del control estocástico (mínima varianza) puede separarse en dos problemas, un problema de predicción estocástica y un problema de control determinístico (esto es conocido como el Teorema de la separación). Este problema de control determinístico finalmente es el mismo problema del control predictivo.

2.2.2 El Control Predictivo con Redes Neuronales

Como vimos anteriormente, dentro de los controladores predictivos podemos incluir aquellos en los que se contempla el modelo de perturbación en forma estadística (estos controladores se han denominado históricamente reguladores de mínima varianza), veremos ahora la implementación de controladores predictivos con redes neuronales. Aquí el proceso de control consiste en determinar el valor de control siguiente $u(n + 1)$, a partir del comportamiento futuro del sistema.

Tomando como base lo reportado por G. Cakmak¹³, podemos inferir que para desarrollar un control predictivo (con redes neuronales) es necesario realizar los pasos de modelado, identificación, diseño del control y análisis de sensibilidad, incluso puede ser necesario también repetir algunos pasos hasta obtener un resultado satisfactorio. Por tal motivo tiene un considerable interés explorar las posibilidades de simplificación del procedimiento de desarrollo de controladores. Esto se debe hacer incluyendo en el neuro-controlador, algoritmos para estimación de parámetros y de cálculo de la ley el control.

Estas simplificaciones propuestas nos conducen al denominado Regulador Auto Sintonizado (Self Tuning Regulator) el cual tiene la capacidad de sintonizarse a sí mismo. Es importante destacar que los sistemas en lazo cerrado que se obtienen con reguladores auto-sintonizados son sistemas no lineales y variables en el tiempo. Ahora bien, si efectuamos algunas pequeñas modificaciones a un regulador auto sintonizado tenemos un control adaptivo, el cual puede manipular sistemas con amplias variaciones en los parámetros característicos.

En nuestro sistema de control, a la vez que se alimenta la planta, y antes de correr el algoritmo de optimización, puede aplicarse un algoritmo de entrenamiento a la red neuronal en línea; de esta manera la red se adaptará a los cambios en la planta real. Además puede utilizarse la identificación a partir de un modelo aproximado, con lo cual el modelo se perfecciona en línea, a medida que el tiempo pasa.

A continuación, en la figura 6 se puede ver un primer esquema de controlador predictivo con redes neuronales, allí, mientras se realiza la predicción los interruptores s_i hacen que la planta quede desconectada, pero aún así ésta debe ser alimentada con el valor de control actual $u(n)$, hasta tanto no se determine $u(n + 1)$.

El primer paso en el proceso de control consiste en definir y_r , es decir, la forma en que la red neuronal debe cambiar su valor inicial ($y_m(n) = y_p(n)$) hasta alcanzar el valor de consigna. Lo que continúa es hacer que la salida de la red y_m se acerque tanto como sea posible a y_r ; esto se logra modificando el valor de control $u(n + 1)_i$, comenzando por el que alimenta la planta real en ese instante ($u(n + 1)_1 = u(n)$). Cuando se encuentra un valor de control adecuado, se cambia la posición de los interruptores y se alimenta con él a la planta.

¹³ G. Cakmak; C. Yildiz, **The prediction of seedy grape drying rate using a neural network method.** *Computers and Electronics in Agriculture*, vol. 75 pages 132 -138. Elsevier Science, 2011.

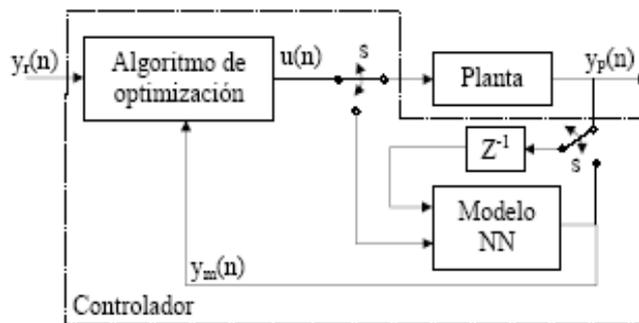


Figura 6 Esquema genérico del Control Predictivo con Redes neuronales

Además de minimizar la diferencia entre y_r y y_m , es recomendable tener en cuenta el cambio en el valor de control ($\Delta u = u(n+1) - u(n)$), penalizando valores elevados mediante un coeficiente de ponderación λ ; de esta manera se define la suavidad con que y_p se desempeñará. Todo el proceso de control ya visto se puede resumir en un algoritmo de optimización, como el detallado a continuación.

- 1) Se inicia con la selección de la ventana de predicción $[N_1 \ N_2]$, del horizonte de control N_U y del coeficiente λ . Estos son los parámetros con que se sintoniza al controlador.
- 2) Se genera la trayectoria de referencia y_r en la ventana de predicción.
- 3) Se simula el comportamiento del sistema y_m usando la red neuronal. Se alimenta con el valor de control actual $u(n)$.

$$J = \sum_{i=N_1}^{N_2} [Y_r(n+i) - Y_m(n+i)]^2 + \lambda \sum_{i=1}^{N_U} [u(n+i-1) - u(n+i-2)]^2$$

- 4) Se escoge $u(n+1)$, buscando que minimice la función de costo descrita en siguiente ecuación:
- 5) Se repite el paso 3 y 4, hasta tanto $u(n+1)_i - u(n+1)_{i-1}$ sea menor a una cota, la cual depende de la precisión con que se quiera el cálculo.
- 6) Se asigna al valor de control del paso 5 como $u(n+1)$ y se alimenta con éste a la planta real. En este paso debe cambiarse la posición de los interruptores (s)
- 7) Se repite desde el paso 1, todo el tiempo que quiera controlarse el sistema.

U. Levin and K. Narendra¹⁴, demostraron que las redes neuronales identifican sistemas no lineales y además son útiles para su control, las razones fundamentales por las que una red neuronal sirve para identificar son sus adaptabilidad, robustez y paralelismo, especialmente cuando el proceso a modelar es una caja negra o si se conoce muy poco de la dinámica del sistema, debido a que se ajustan a la información de entrada-salida con que se les entrene, la cual es asumida como ejemplos de aprendizaje.

Las redes neuronales tienen la capacidad de aprender, por lo que si conocemos la entrada del sistema, la salida objetivo (consigna) y la salida real del sistema ante una entrada dada, un controlador integrado por una red neuronal sería capaz de modificar sus parámetros aprendiendo la dinámica de la planta hasta conseguir un sistema fiable¹⁵⁻¹⁶. Principalmente, para el diseño de controladores a partir de modelos de la planta que son lineales e invariantes con el tiempo, hay dos posibles enfoques para contemplar la incertidumbre en el modelo del sistema y las perturbaciones sobre este.

El primero de ellos es considerar las incertidumbres del sistema en el diseño de un controlador fijo, lo cual lleva a un esquema de control robusto, que es más insensible a las variaciones en los parámetros y a las perturbaciones. El segundo enfoque es utilizar un controlador adaptivo, el cuál estima los parámetros y

¹⁴ U. Levin and K. Narendra, **Control of nonlinear dynamical systems using neural networks: controllability and stabilization**, *IEEE Trans. on Neural Networks*, vol. 4, no. 2, pp. 192-206, 1993.

¹⁵ I. Farkas; P. Reményi; A. Biró, **A neural network topology for modelling grain drying**. *Computers and Electronics in Agriculture*, vol. 26, pages 147 -158. Elsevier Science, 2000.

¹⁶ I. Farkas; P. Reményi; A. Biró, **Modelling aspects of grain drying with a neural network II**. *Computers and Electronics in Agriculture*, vol. 29 pages 99 -113. Elsevier Science, 2000.

calcula la señal de control basándose en dichos parámetros. La metodología de los reguladores autoajustables es la adecuada en este caso, pero conlleva el diseño en línea, con el esfuerzo de cálculo necesario para ello, mucho mayor que en el caso de un regulador más simple.

2.2.3 El Control Adaptivo con Redes Neuronales

El uso del controlador adaptivo también hace que sea necesario conocer la estructura del sistema, saber si se trata de un sistema lineal o no lineal y conocer el orden del sistema en concreto. Sin embargo, con la ayuda de las redes neuronales artificiales podemos paliar estos inconvenientes, ya que gracias a estas conseguiremos prescindir de métodos de cálculo complejos y costosos, minimizando así el tiempo de cálculo, además de poder obviar la estructura del sistema, ya que las redes neuronales son capaces de adaptarse a cualquier tipo de estructura sin necesidad de conocer sus características.

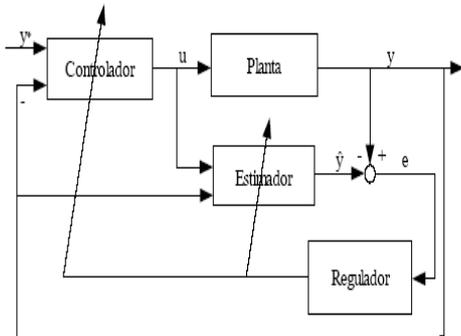


Figura 7.a. Control Adaptivo Clásico

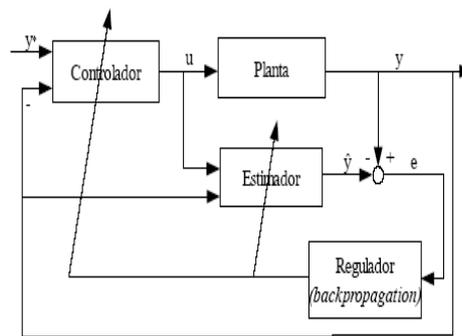


Figura 7.b. Control Adaptivo con Redes Neuronales

Nuestro sistema, se convertiría por tanto en un sistema de control variable en el tiempo ya que la red iría cambiando su estructura con el paso del tiempo y aprendiendo la dinámica del sistema, lo que recibe el nombre de un controlador adaptable. Los controladores adaptables se utilizan para diseñar sistemas de control para plantas que son desconocidas a priori y configuran controladores variables en el tiempo. El esquema básico de control adaptivo, según puede verse en la figura 7a, está compuesto de un lazo principal de realimentación negativa, en el que actúa al igual que en los sistemas convencionales un regulador y de otro lazo en el que se mide un cierto índice de funcionamiento, el cual es comparado con el índice deseado y se procesa el error en un mecanismo de adaptación que ajusta los parámetros del regulador y en algunos casos actúa directamente sobre la señal de control.

El control adaptivo actúa como un control secundario (lazo secundario) influenciando a los parámetros del control primario. El lazo primario debe ser de respuesta más rápida que el lazo secundario, en caso contrario el sistema tendería a saturarse porque se estaría obligando al sistema a reaccionar más rápidamente de lo que puede. Por tanto, el lazo secundario debe variar más lentamente que el lazo primario. Dos enfoques básicos²⁵, han sido referenciados en la documentación de las redes neuronales para abordar el problema del control adaptivo. En el primer caso algunos parámetros del diseño son aprendidos "off-line", midiendo las señales de entrada-salida y observando el comportamiento de la planta en momentos clave. En el segundo enfoque el aprendizaje adaptivo se implementa y la entrada de control se determina "on-line" como la salida de la red neuronal, la señal de control que genera la red es la que genera la salida del sistema que se usa para adaptar los parámetros.

En nuestro sistema de control adaptivo off-line, los bloques funcionales "Controlador" y "Estimador" son el controlador neuronal y el modelo neuronal de la planta respectivamente. Usaremos una red neuronal como modelo de planta (aquí la red aprende la dinámica de la planta usando la regla de BP (backpropagation), tal como se ve en la figura 7.b). O sea que esta red pretende aprender la dinámica de la planta y por lo tanto su salida es la salida estimada del verdadero sistema. El aprendizaje de la dinámica de la planta gracias al estimador neuronal, se usa para ajustar los pesos de conexión de un controlador neuronal que genera la señal de control $u(k)$. Esta señal de control, cuando se aplica a la entrada de la planta, pretende conseguir que la salida de la planta $y(k)$ sea la señal objetivo del sistema. En este sentido, el controlador neuronal está compuesto por una segunda red neuronal. Al trabajar de forma off-line primero se obtienen los valores de los pesos para el controlador y la planta de forma independiente, una vez obtenidos todos los pesos para toda la muestra de datos, estos se utilizan para la simulación de todo el sistema de control.

Por lo tanto, la secuencia de acciones a seguir para el cálculo del sistema de control adaptivo off-line con aprendizaje BP es el siguiente:

1. Obtenemos los valores de entrada y salida referencia para el entrenamiento.
2. Utilizando el aprendizaje BP obtenemos los pesos del controlador neuronal y del modelo neuronal de la planta.
3. Simulamos el sistema de control usando los pesos obtenidos en anterior apartado.

2.3.4 El Control Adaptivo con Redes Neuronales y múltiples modelos

En esta última sección analizamos el caso en que la red neuronal aprende “on-line” la dinámica del sistema, la cual minimiza la diferencia entre la señal de salida actual de la planta y la salida pronosticada por la red. Recordemos que al inicializar los parámetros de una red neuronal no podemos saber cuáles van a ser los más adecuados para que el sistema minimice el error de la forma más rápida posible, por eso se inicializan estos parámetros de forma aleatoria. Es posible por tanto, que los parámetros elegidos en forma aleatoria alcancen una convergencia muy lenta. Durante el intervalo en el que aprende se está controlando en forma deficiente el sistema y por tanto la salida es mala. Adicionalmente, la velocidad de convergencia de la red depende de la red neuronal utilizada y en los casos en los que se utilizan redes neuronales estándares pueden surgir velocidades de convergencia lentas, lo que hace que sea un problema en la práctica.

Para solucionar estos problemas de velocidad de convergencia y estabilidad en el sistema de control recurrimos a un sistema capaz de decidir el mejor “camino” entre múltiples modelos, para reducir al máximo el tiempo de aprendizaje del sistema y por lo tanto estabilizar e igualar en corto tiempo la señal de salida del sistema a la señal objetivo (controladores adaptivos con redes neuronales y múltiples modelos).

Este sistema, según Ibeas¹⁷, se basa en multiplicar los nodos de salida y seleccionar según un criterio la mejor salida, esta es normalmente la que hace converger la señal más rápidamente. Es un proceso que selecciona una salida en tiempo de cálculo, utilizando un sistema de conmutación que escoge siempre la mejor salida, por lo que salida que se selecciona varía en el tiempo, pudiendo existir una conmutación constante.

Esta selección entre múltiples modelos de planta, se realiza según una muestra y criterio, como por ejemplo, tomando los errores de las últimas cinco iteraciones y seleccionando la salida con la media de error más baja. Esto no quiere decir que en todos los sistemas de modelos múltiples se conmute entre todas las salidas, si en un sistema las salidas multiplicadas adicionales devuelven errores mayores a la salida original de la red no existirá ninguna conmutación. Ilustraremos a continuación sobre el procedimiento empleado para obtener, a partir de una red neuronal, múltiples modelos de salida.

En la figura 8.a, adaptaremos la red neuronal de dos salidas con un multiplicador de salidas quedando así, la red de la figura 8.b (tengamos en cuenta que para adaptar esta red neuronal a un sistema de múltiples modelos además de multiplicar por la constante multiplicadora del sistema M las salidas, también debemos multiplicar por M la matriz de pesos sinápticos de la capa de salida, ya que cada grupo de salidas dispone de sus propias matrices independientes de pesos).

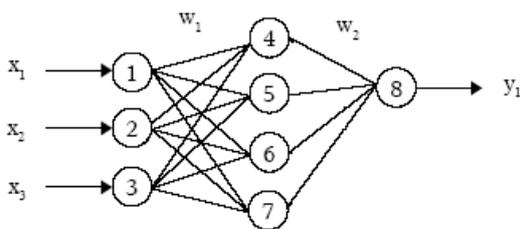


Figura 8.a. Esquema con una sola salida

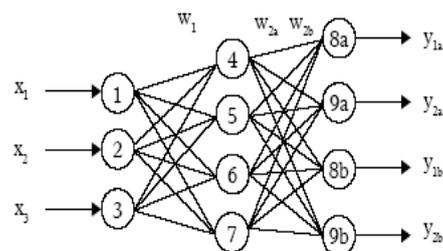


Figura 8.b. Esquema con múltiples salidas

Multiplicando la capa de salida e inicializando los parámetros de salida de los pesos de forma aleatoria podemos compensar una desviación inicial del error más rápidamente. Para aprovechar esta característica de forma correcta se utiliza una lógica de conmutación (switching) que elige en cada intervalo de tiempo el conjunto de parámetros con el error entre la salida y la salida deseada más pequeño.

Dado que se procesa en paralelo se hacen más cálculos pero no requieren más tiempo y de esta forma estamos incrementando la velocidad de aprendizaje, consiguiendo que el sistema se adapte mucho más rápido a la salida que deseamos obtener. Además es de destacar que, se ha estudiado en detalle^{18,19} la

¹⁷ A. Ibeas, M. De La Sen, S. Alonso-Quesada, **Stable multiestimation model for single-input single-output discrete adaptive control systems**, *International Journal of Systems Science.*, Ed. Elsevier, 2004.

¹⁸ A. S. Morse, **Control using logic-based switching**. In A. Isidori, editor, *Trends in Control: A European Perspective*, pages 69 -113. Springer-Verlag, 1998.

estabilidad y robustez de algoritmos que trabajan en paralelo y en forma conmutada, con el fin de calcular la ley de control adaptiva.

3. Conclusiones

Hemos revisado algunos elementos que hacen al diseño de una estrategia de control de procesos de secado de granos empleando redes neuronales adaptivas. Luego de una primera especificación del problema y una discusión de los modelos clásicos empleados en el secado de granos, abordamos el tema de los observadores, es decir dispositivos tendientes a estimar el valor de variables de estado que no son fácilmente medibles en los procesos de secado, tal como es justamente la misma humedad del grano. En este contexto introducimos las redes neuronales adaptivas como observadores eficientes para esta situación.

Sobre esa base bosquejamos los rudimentos de un control de mínima varianza, tendiente a asegurar una calidad uniforme del secado. Analizamos también las variantes adaptivas del control de mínima varianza, estrategias importantes a la hora de considerar los retardos propios de la planta, las no linealidades presentes y las posibles perturbaciones aleatorias, analizamos también la implementación de controladores adaptivos con redes neuronales mediante estrategias que recurren al entrenamiento de la red fuera de línea o bien en línea y finalmente analizamos la implementación a través de múltiples modelos y conmutación de los mismos con un criterio de supervisión eficiente, del control de secado de granos con redes neuronales en tiempo real. Como trabajo futuro estamos explorando en detalle este esquema de controlador adaptivo con redes neuronales y múltiples modelos (técnica conocida como: Multiple Models, Switching and Tuning) que permite alcanzar un aprendizaje on-line eficiente.

¹⁹ K. S. Narendra and J. Balakrishnan, **Adaptive control using multiple models**. *IEEE Trans. on Automatic Control*, vol. 42, no. 2, pp. 171-187, 1997.