

## Pronósticos para el Rendimiento Del Trigo Usando Redes Neuronales Artificiales

Reporte de proyecto

M.C. y T. Adriana Saldaña-Robles<sup>a,b</sup>, Dr. S. Jöns<sup>a</sup>, Dr. Saldaña-Robles N.<sup>b</sup>, Ing. Damián-Ascencio C.E.<sup>c</sup>

<sup>a</sup> CIATEC A.C., Omega 201, Fracc. Ind. Delta. León, Gto.

<sup>b</sup> Campus Salamanca-Irapuato, División Ciencias de la Vida, Universidad de Guanajuato.

<sup>c</sup> Campus Salamanca-Irapuato, División de Ingenierías, Universidad de Guanajuato.

e-mail: jons\_sanchez@hotmail.com, adryi10@gmail.com

### Resumen

En el presente trabajo se desarrolló un modelo de predicción de rendimiento, empleando datos de temperatura del aire, humedad del aire desde 1980 hasta el 2007 para el estado de Guanajuato. Para la predicción de rendimiento se utilizó una red neuronal artificial con una estructura del tipo feed-forward back propagación. Se realizaron pruebas con diferentes arquitecturas en la estructura de la red neuronal, el método de entrenamiento utilizado fue el algoritmo de Levenberg-Marquardt y el error fue evaluado con el MSE. Adicionalmente se alimentó la red neuronal con arreglos diferentes como elementos de entrada. El modelo fue validado con los datos del 2007. Los resultados muestran que los mejores elementos para predecir el rendimiento fueron: los arreglos de temperatura y humedad del aire, los cuales mostraron un MSE de 0.0036.

**Palabras clave:** Rendimiento, Redes Neuronales Artificiales, Trigo.

### Abstract

In this paper we have built a yield prediction model, we took in consideration air temperature and air humidity from 1980 to 2007 in the state of Guanajuato, México. For the prediction of yield we used an artificial neural network with a structure named feed-forward back propagation. We tested with different architectures in the structure of the neural network, the training method used was the Levenberg-Marquardt algorithm and we evaluated the error through the MSE. Additionally, the neural network was fed with different arrangements as input. We validated the model, using data from last year. Results showed that the best elements to predict the yield were the arrays of temperature and humidity, which estimated a MSE on 0.003.

**Key words:** Yield, Artificial Neural Networks, Wheat.

### Introducción

El rendimiento agrícola se define como la producción dividida entre la superficie utilizada para la siembra. Un mayor rendimiento indica una mejor calidad de la tierra o una explotación más intensiva, en trabajo o en técnicas agrícolas.

En la década de los 90's la necesidad de mejorar la predicción de la producción llevó a buscar métodos para predecir una estimación de ésta, empleando como base la predicción del rendimiento y la superficie cosechada. Entre los primeros métodos que surgieron, se encontró el Método Par, el cual se basaba en 10 años de las condiciones de rendimiento y condiciones climáticas proporcionadas por los granjeros, esto se hacía considerando un modelo lineal. Otro método que surgió fue mediante regresión lineal que marco un gran avance en la predicción de rendimiento, entre algunos otros métodos [1].

En la actualidad, los métodos comunes en la predicción del rendimiento son modelos de regresión lineal múltiple, los cuales están basados en condiciones climáticas tales como la temperatura, la lluvia y la radiación. Otras técnicas tales como los métodos de simulación, toman en cuenta además de las variables de alimentación climatológicas, condiciones propias del cultivo tales como, la biomasa de la raíz y de la planta, entre algunas otras [2]. Muchos de estos métodos utilizados en la predicción de rendimiento están basados en el supuesto de un comportamiento lineal, lo que en condiciones climatológicas no es una realidad, por esto, es necesario buscar métodos más precisos que permitan estimar el rendimiento de un cultivo con un menor margen de error.

Debido al comportamiento no lineal que presenta el rendimiento, las redes neuronales artificiales (ANNs por sus siglas en inglés Artificial Neural Networks) son un excelente candidato para la predicción de esta estimación. Las ANNs son usadas en modelos y sistemas altamente no lineales [3].


En general las ANNs son técnicas matemáticas simples diseñadas para cumplir una gran variedad de tareas. Hoy en día las ANNs pueden ser configuradas en varios arreglos para desarrollar diversas tareas, tales como, el reconocimiento de patrones, minería de datos, clasificación y predicción, entre otras [4]. Las ANNs están compuestas de atributos que aprenden soluciones en aplicaciones donde se necesita un mapeo lineal o no lineal. Algunos de estos atributos son: capacidad de aprender, generalización y procesamiento en paralelo, estos atributos hacen que las ANNs puedan resolver problemas complejos haciendo de esta técnica un método preciso y flexible [5, 6, 7].

Una ANN consiste en una interconexión de un número determinado de neuronas. Hay una gran variedad de interconexiones, para este estudio en particular se estudiará el tipo de red perceptrón multicapa, un perceptrón multicapa está compuesto por una capa de entrada, una capa de salida y una o más capas ocultas. En la Figura 1 se puede observar un perceptrón típico formado por una capa de entrada, una capa oculta y una de salida. Las conexiones entre neuronas son siempre hacia delante: las conexiones van desde las neuronas de una determinada capa hacia las neuronas de la siguiente capa; no hay conexiones laterales ni conexiones hacia atrás. Por lo tanto, la información siempre se transmite desde la capa de entrada hacia la capa de salida. Se considera  $w_{ji}$  como el peso de conexión entre la neurona de entrada  $i$  y la neurona oculta  $j$ , y  $w_{kj}$  como el peso de conexión entre la neurona oculta  $j$  y la neurona de salida  $k$ .

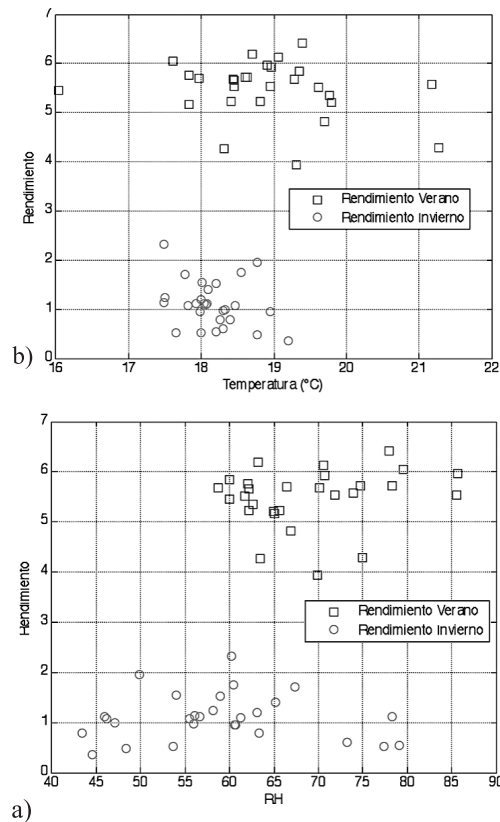
**Diseño de la red**

Un problema importante en las ANN es el diseño de una red con el adecuado número de neuronas ocultas para aprender un determinado concepto. Si una red tiene pocas neuronas ocultas, esta red no tendrá el poder de cómputo para aprender bien el concepto. Si existen demasiadas neuronas ocultas, la red se sobreentrenará y no podrá predecir correctamente al alimentarla con nuevas entradas.

Para la predicción del rendimiento, se probó de manera heurística con los parámetros climáticos (temperatura y humedad relativa) usados comúnmente para la predicción del rendimiento.



**Figura 1.** ANNs tipo perceptrón multicapa



**Figura 2.** Variación del rendimiento con a) la temperatura y b) la humedad relativa.

Adicionalmente, se probó alimentando como valor de entrada a la red, el rendimiento en el semestre anterior. Los datos de temperatura y humedad utilizados para alimentar la red fueron tomados de los promedios semestrales desde el año 1980 a 2007 como se muestra en la Figura 2.

El historial de rendimientos para el estado de Guanajuato fue tomado de la base de datos de SIACON de trigo para riego más temporal (Figura 2). De igual manera que para los datos de temperatura y humedad relativa, se tomaron los promedios semestrales para el entrenamiento de la red, dejando el último año para la validación de la misma.

La calidad del entrenamiento de la red neuronal fue determinada mediante el error medio cuadrático (MSE), el cual se define como:

$$MSE = \frac{1}{n} \sum (y_i - \bar{y}_i)^2 \quad (1)$$

Donde  $y_i$  representa el valor observado y  $\bar{y}_i$  el valor predicho por la red.

El entrenamiento, inicializó las interconexiones de la red empleando algoritmos genéticos (Esta técnica ha demostrado ser útil para disminuir el tiempo de entrenamiento y la optimización de la arquitectura [7]) y posteriormente optimizando la solución mediante el algoritmo de Levenberg-Marquardt, utilizando la función de activación logística definida mediante la ecuación 2:

$$\text{logsig}(z) = \frac{1}{1+e^{-z}} \quad (2)$$

La arquitectura de la red fue variada de forma sistemática, primero cambiando el número de entradas de la red y posteriormente cambiando el número de neuronas de la capa oculta desde 1 hasta 3 como se ilustra en el ejemplo de la Figura 3. Para seleccionar el mejor modelo (se eligió la de menor MSE) para cada caso. Por ejemplo, la primera estructura empleada consistió de 5 entradas y 1 salida, con cero neuronas en la capa oculta.

Las entradas de la red consistieron en los valores de las temperaturas y humedades relativas semestrales del año anterior a la predicción, mientras la quinta entrada representa el rendimiento del semestre anterior (como se muestra en la Figura 3-a). Una vez entrenada la red anterior se fueron incrementando las neuronas hasta el máximo valor permitido sin cometer un sobre entrenamiento.




Figura 3. Red empleada para a) cero neuronas b) una neurona, c) dos neuronas, d) tres neuronas en el nivel oculto para la red con cinco entradas.

De la misma manera que para el caso de la red con cinco entradas, las otras arquitecturas propuestas fueron construidas variando el número de neuronas en la capa oculta.

### Resultados y discusión

Como se muestra en la Figura 4, al variar el número de neuronas en la capa oculta, el MSE fue disminuyendo llegando a un mínimo cuando la red tuvo 3 neuronas en la capa oculta. Como se observa, para el caso de la red con tres entradas, el número de neuronas en la capa oculta máximo que se pudo emplear fue superior al de los casos con 4 y 5 entradas, debido a que al tener menor número de neuronas de entrada, la red permitió utilizar más neuronas en la capa oculta sin llegar al sobre entrenamiento.




Figura 4. Variación de error medio cuadrático para distintos esquemas de la red.

Como se muestra en la Figura 4, la red que proporcionó el menor MSE fue la red con 5 entradas, sin embargo, como se observa en a Figura 5, la predicción para verano para las redes con 5 y 3 entradas presentaron una mayor desviación del valor esperado para el año del 2007. Debido a que al tener un mayor número de neuronas, la red pudo quedar cerca del sobre ajuste y, aún teniendo un menor MSE la predicción resultó ser inexacta. Cabe señalar que con un mayor número de neuronas, se presentó un síntoma de sobre ajuste, esto significa que la red trabajó muy bien con el conjunto de datos de entrenamiento, pero produjo malos resultados con el conjunto de datos de validación.




Figura 5. Predicciones para los rendimientos en 2007.

Por otra parte, al analizar las predicciones hechas en el semestre de invierno, se observa que los valores estimados por las redes están aproximadamente en el mismo margen.

Finalmente, en la Tabla 1 se resumen los parámetros de las predicciones realizadas con las redes neuronales. Donde el subíndice de las T's y RH's significa invierno (i) y verano (v); asimismo "Rea" representa rendimiento del ciclo anterior.

Tabla 1. Error cuadrático medio obtenido para las estructuras propuestas

Estructura de la red	Estructura	MSE	Predicho verano	% Error	Predicho invierno	% Error
$T_i-T_v-RH_i-RH_v$	4:3s:1s	0.0036	1.13	0.79	6.22	0.29
$T_i-T_v-RH_i-RH_v-Rea$	5:3s:1s	0.0020	1.20	7.38	4.28	30.9
$T_i-T_v-Rea$	3:3s:1s	0.0024	1.24	10.87	4.41	28.8

### Conclusiones

Es indudable que hoy en día las redes neuronales están demostrando su capacidad para resolver problemas de pronóstico altamente complejos. Sin embargo, pese a estas evidencias de éxito aún hay aplicaciones en nuestro entorno, como el presente caso, donde se pueden utilizar este tipo de herramientas.

Dicho lo anterior, el presente trabajo se enfocó en la estimación del rendimiento del trigo para el estado de Guanajuato usando redes neuronales artificiales. Los resultados muestran que el uso de estos algoritmos proporcionan una herramienta más exacta para la predicción del rendimiento, por ejemplo, en el ciclo primavera verano se subestimó en 0.29 %. Sin embargo, la arquitectura de la red debe ser seleccionada cuidadosamente para obtener resultados confiables. Para el ejercicio realizado el mejor resultado se obtuvo con una arquitectura de 4 neuronas de entrada, 3 neuronas en la capa oculta y una neurona de salida y un MSE de 0.003636.

Es necesario realizar un análisis comparativo de esta red neuronal contra otros métodos de predicción tales como modelos de regresión empírica, modelos de simulación o métodos no-paramétricos. Y de esta forma, en un trabajo futuro se desarrollará un modelo más robusto que incluya otras variables exógenas por ejemplo, precipitación pluvial, radiación, tipo de suelo, técnicas agrícolas de producción entre otros factores.

### Referencias

- [1] Vogel, F. A., (1988), "125 Years of Agricultural Estimates", USDA-MASS-SSD (EUA), pp. 1-5.
- [2] Gommers, R., (2008), "Crop Yield Forecasting Systems", National Seminar on Crop Yield Forecasting, p. 5-15, Sunway Hotel, Phom Penh.
- [3] Azadeh, A.; Ghaderi, S. F.; Sohrabkhani, S., (2008), "Annual Electricity Consumption Forecasting by Neural Network in high Energy Consuming Industrial sectors", Energy Conversion and Management. Volumen 49, Issue 8, p. 2272-2278.
- [4] Vahidinasab, V.; Jadid, S.; Kazemi, A., (2008), "Day-ahead price Forecasting in Restructured Power Systems using Artificial Neural Networks", Electric Power Systems Research. Volumen 78, Issue 8, p. 1332-1342.
- [5] Balestrassi, P.P.; Popova, E.; Paiva, A.P.; Marangon, J.W., (2009), "Design of experiments on Neural Network's training for nonlinear Time Series Forecasting" Neurocomputing, volumen 72, Issues 4-6, p. 1160-1178.
- [6] Freeman, J.; Skapura, D., (1991), Neural Networks Algorithms, Applications, and Programming Techniques, Addison-Wesley, New York.
- [7] Rabuñal, J. R.; Dorrado, J., (2006), Artificial neural networks in real-life applications, Idea Group Publishing, USA.

Artículo recibido: 20 de mayo de 2010

Aceptado para publicación: 29 de noviembre de 2010