

Modelo inteligente para monitoreo del desarrollo de plantas de maíz Smart model for monitoring maize plant development

Silvia Soledad Moreno Gutiérrez, Jesús Cornejo Álvarez, Edgar Abraham Gudiño Olgúin, Mónica García Munguía, Sócrates López Pérez
Universidad Autónoma del Estado de Hidalgo
silviam@uaeh.edu.mx
Buena vista no. 608, Col. Cuauhtémoc, CP. 42020 Pachuca Hgo.
7711275849

Fecha de recepción: 03 de julio de 2019

Fecha de aceptación: 30 de agosto de 2019

Resumen. La seguridad alimentaria juega un papel crucial para la supervivencia humana, hoy en día se ve amenazada mundialmente por la variabilidad climática y por los efectos adversos que este fenómeno ha ocasionado sobre los cultivos de maíz, que, conjuntamente con el arroz y el trigo conforman el alimento más importante del mundo. Siendo el maíz uno de los cultivos más dañados por el cambio climático, es prioritario monitorear su desarrollo de manera precisa y con mayor frecuencia que la actual. Al respecto, la revisión de la literatura expresa la ausencia de herramientas computacionales de alta precisión y bajo costo que apoyen al agricultor en esta tarea, por ello, se construyó una red neuronal artificial de aprendizaje híbrido capaz de monitorear el desarrollo del cultivo e identificar posibles deficiencias de forma oportuna con una precisión del 98%; de esta forma la propuesta contribuye a reducir pérdidas y apoya la seguridad alimentaria.

Palabras Clave: Maíz, Redes Neuronales Artificiales, Cambio Climático, Monitoreo.

Summary. Food security plays a crucial role for human survival, today it is threatened globally by climate variability and the adverse effects that this phenomenon has caused corn crops, which, together with rice and Wheat make up the most important food in the world. Corn being one of the crops most damaged by climate change, it is a priority to monitor their development of precise way and more frequently than the current one. In this regard, the literature review expresses the absence of high precision and low cost computational tools that support the farmer in this task, therefore, an artificial neural network of hybrid learning capable of monitoring crop development and identifying possible deficiencies in a timely manner with an accuracy of 98%; in this way the proposal contributes to reducing losses and supports food security

Keywords: Corn, Artificial Neural Networks, Climate Change, Monitoring.

1 Introducción

El maíz es el cereal de mayor consumo a nivel mundial y forma parte de la canasta básica de los seres humanos, en México este grano es pilar económico del sector cerealista por sus niveles de producción, como generador de empleos y como alimento para la población [1]. A nivel mundial México ocupa el 6° lugar en producción con un total de 27,762,781 toneladas en 2017 [2].

Para alcanzar óptimos niveles de producción las condiciones meteorológicas y el monitoreo de los cultivos son fundamentales, no obstante, a consecuencia del Cambio Climático (CC) en los últimos años el sector cerealista ha sufrido grandes pérdidas debido a la temperatura que aumentó 0.85°C respecto al año 1960 y que ha ocasionado cambios en los patrones climáticos [3], fenómeno que según [4] es ocasionado directa o indirectamente por la actividad humana.

El CC muestra efectos benéficos y perjudiciales para el sector, mencionan [5], sin embargo, por su vulnerabilidad ante el clima, el sector cerealista ha sido gravemente dañado, en mayor medida los cultivos de maíz, papa y haba [6].

A finales del siglo XXI, América Latina será la zona más afectada expresan [7], se estima un aumento en la temperatura entre 1,6 a 4 °C, con graves efectos para el cultivo [8], reducción de la producción en un 10% para 2055 [9], y daño en la seguridad alimentaria [10].

Con base en lo anterior, se efectuó una revisión de la literatura para identificar propuestas del sector cerealista para reducir pérdidas relacionadas con el CC, al respecto, se encontraron trabajos que se describen en el apartado siguiente Panorama reducido del estado del arte, sin embargo, no se encontraron herramientas de alta precisión para monitoreo de cultivos.

El presente trabajo expone la construcción de un sistema para monitorear el desarrollo del cultivo de maíz mediante una red neuronal artificial (RNA), apoyada en una interfaz gráfica que permita al usuario obtener resultados de manera sencilla, que le apoyen en la toma de decisiones.

2 Panorama reducido del estado del arte

En los últimos años el sector cerealista se ha apoyado en el modelado matemático, estadístico y computacional con mayor énfasis en la predicción y en la simulación del cultivo, esto con el propósito de reducir pérdidas ocasionadas por el CC. Algunos de estos trabajos se mencionan a continuación.

2.1 Modelos de simulación de cultivos

Los modelos de simulación de cultivos son genéricos como DSSAT, DNDC, APSIM, CROPWAT, WOFOST, ET0 CALCULATOR, SIMPROC, AMBER, BEKLIMA, AGROMET 2.9.0.3, VEGSYST [11]. Algunos de los modelos emplean regresión lineal simple, regresión lineal múltiple y no lineal: exponencial, logística, mono molecular y michaelis-menten para estimar el crecimiento de los cultivos [12].

Para el cultivo de maíz se encuentra el modelo CERES-MAIZE, de los más destacados por su eficiencia en la simulación de desarrollo y rendimiento [13]. AQUA-CROP modelo de simulación del rendimiento con base en el agua y CC con alto nivel de asertividad [14], el CROP-SYST, genérico adaptado al maíz con buenos resultados [15]. Otros modelos son STICS [16], SIMDUALKC [17], EPIC [18], HYBRID-MAIZE [19], SUCROS [20]. Además, el sector del cereal ha sido fuertemente apoyado mediante modelos basados en técnicas tradicionales, las cuales son de amplia aceptación, algunos trabajos son los de planeación de fechas para siembra de maíz, que han logrado incremento de rendimiento [25], otras propuestas son: modelo de predicción de gusano en planta de maíz [26], predicción de rendimiento del grano de maíz basado en su fenología [27].

A pesar de sus buenos resultados, las propuestas anteriores muestran deficiencias en lo general, relacionadas con la predicción bajo altas temperaturas.

2.2 Modelos con RNA

En la literatura revisada se encontraron los trabajos que se mencionan a continuación.

[21], proponen un modelo backpropagation para clasificar imágenes de planta o maleza, [22] crearon un sistema de visión artificial para agricultura de precisión. [23] desarrollaron un perceptron multicapa para estimar la lámina de agua total en el suelo durante la estación de crecimiento, [28] construyeron una red neuronal de Grey para predicción de rendimiento de grano, de igual forma [29] en su caso basados en datos de fertilizantes, biocida y maquinaria.

Por su parte [30] desarrollan modelo basado en precipitación y fertilizante, [33] predicen la variabilidad del rendimiento y tolerancia de salinidad del suelo para trigo, [32] Construyen red neuronal de picos para predicción de cultivos de cereal básico.

[31] Construyen modelo de predicción de malezas en cultivo de maíz, [34] expresa el apoyo fuerte de los modelos inteligentes al sector del cereal con precisión es alta.

La literatura revisada expone sistemas inteligentes con objetivos diferentes, sin embargo ninguno dedicado al monitoreo del desarrollo del cultivo.

3 Metodología

Se construyó un sistema inteligente apoyado en una RNA de aprendizaje híbrido y una interfaz gráfica. Los datos para el entrenamiento y validación de la RNA fueron extraídos de la base de datos (BD) mundial disponible en internet.

Para el entrenamiento se empleó un total de 22,302 registros diarios y para la validación fueron 6,021 todos ellos provenientes de diferentes zonas del mundo, 25,000 registros corresponden a años de 1997 a 2017 y 1021 registros son del año 2019.

La metodología empleada consiste en lo siguiente:

- 1) Se diseñó la RNA de base radial
- 2) Posteriormente se extrajeron los patrones climáticos necesarios de la BD y se efectuó su normalización
- 3) Se realizó análisis de las variables climáticas y del efecto adverso sobre el desarrollo de la planta
- 4) Como cuarto paso se construyeron las matrices de entrada y salida esperada, además de las correspondientes matrices para validación. Esto con base en los resultados del punto 3
- 5) Como quinto paso se entrenó la RNA
- 6) Finalmente se llevó a cabo la validación

3.1 Arquitectura

La RNA de base radial está compuesta por 6 neuronas de entrada, con una capa oculta de 6 neuronas y 13 neuronas de salida, se aprecia en la figura 1.

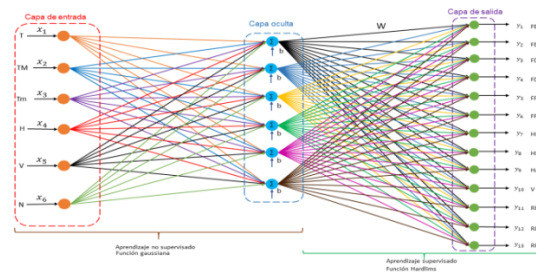


Figura 1. RNA de monitoreo del maíz

Cada neurona de entrada representa un factor climático: T = Temperatura media, TM = Temperatura Máxima, Tm = Temperatura Mínima, H = Humedad, V = Velocidad del Viento, N = Niebla del día

Cada neurona de salida representa una causa de daño en su etapa de desarrollo: FEC = Fase de Emergencia por calor, FEF = Fase de Emergencia por frío, FDC = Fase de Desarrollo por calor, FDF = Fase de Desarrollo por frío, FFC = Fase de Floración por calor, FFF = Fase de Floración por frío, HE = Helada, HB = Humedad Baja, HA = Humedad Alta, V = Velocidad del Viento, RE = Radiación Baja en Emergencia, RD = Radiación Baja en Desarrollo, RF = Radiación Baja en Floración.

3.2 Aprendizaje

Para el entrenamiento de la RNA propuesta se utilizó un total de 16,280 registros climáticos diarios y se empleó el aprendizaje híbrido, el cual se compone de dos fases, una de aprendizaje no supervisado y la otra de aprendizaje supervisado, el bloque siguiente expone la forma en que se efectuó este proceso.

3.2.1 Fase 1. Aprendizaje no supervisado

La primera fase de aprendizaje de la RNA propuesta, se realizó empleando el algoritmo K-medias o k-means, para la clasificación de grupos [35] o patrones de entrada a la red en 6 grupos, los pasos que se siguieron son:

Dado el número de clases $k = 6$

1. Se inicializaron aleatoriamente los centros de los k clústers o grupos
2. Se asignaron N_i patrones de entrada a cada clúster i de la siguiente forma:

El patrón $X(n)$ pertenece al clúster i si:

$$\|X(n) - C_i\| < \|X(n) - C_s\| \quad \forall_s \neq i, s = 1, 2 \dots K$$

Cada uno tiene asociado un determinado número de patrones de entrada, y son aquellos más cercanos a su centro.

3. Actualización: se calcularon los nuevos centros como la media de todos los patrones que pertenecen al clúster, con base en la expresión:

$$c_{ij} = \frac{1}{N} \sum_{n=1}^N \mu_A(x(j)) \forall j = 1, 2, \dots, K$$

- Se repitieron los pasos 2 y 3 hasta que las nuevas posiciones de los centros no se modifiquen con respecto al anterior

$$\|C_i(t) - C_i(t-1)\| < \varepsilon, \forall i = 1, 2, \dots, K$$

Se empleó la distancia euclidiana para determinar la distancia de los centros a sus vecinos más cercanos

$$d_E(P_1, P_2) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

3.2.2 Fase 2. Aprendizaje supervisado

En esta fase se empleó el algoritmo de Widrow y Hoff el cual se emplea en el aprendizaje supervisado [24] para la obtención de la matriz de aprendizaje integrada por los pesos sinápticos, el conjunto de pasos que dan lugar al algoritmo utilizado es el siguiente.

- Calcular R $R = \frac{1}{L} \sum_{i=1}^m z z^T$
- Calcular h $h_x = \frac{1}{L} \sum_{i=1}^m t_i z_i$
- Obtener w y b $W b_i = R^{-1} h_x$

La función de activación empleada para este caso fue hardlims.

$$a = \begin{cases} 1 & \text{si } n \geq 0 \\ -1 & \text{si } n < 0 \end{cases}$$

3.3 Interfaz

La interfaz permite al agricultor el ingreso de datos al sistema, relacionados con el clima a través de los factores que muestra la figura 2.

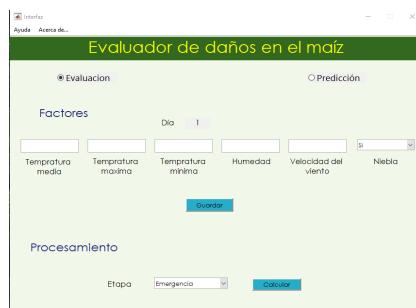


Figura 2. Interfaz de usuario.



Figura 3. Resultados de la evaluación.

A través de la interfaz se observa en color rojo las etapas con daño y también la causa.

4 Resultados

La RNA fue validada empleando un total de 6021 registros climáticos diarios obtenidos de estaciones meteorológicas ubicadas en diferentes regiones del mundo y disponibles en internet, estos registros corresponden al 27% de la totalidad de los datos empleados en el desarrollo de la propuesta (de 22302). El conjunto de registros para validación fue diferente al grupo empleado para el entrenamiento.

A través del desarrollo de un programa de cómputo en lenguaje científico, se llevó a cabo la validación de los nuevos registros por la RNA propuesta, la cual alcanzó un 98% de precisión y así demostró su capacidad de generalización, al ser entrenada con un bloque de registros y posteriormente ser capaz de validar correctamente otros que no participaron en el aprendizaje.

La interfaz gráfica diseñada para facilitar la interacción del usuario con la red y permitirle la captura de registros climáticos presentes o futuros, posibilitó que efectuara sus propias consultas, obteniendo resultados en lenguaje sencillo de fácil comprensión.

5 Conclusiones y trabajos futuros

La RNA es adecuada para el monitoreo del desarrollo de la planta de maíz, el modelo propuesto permite evaluar cualquiera de las etapas del cultivo bajo efectos de los factores climáticos expuestos como variables de entrada a la RNA. El modelo de base radial resultó decisivo para el éxito de la propuesta y su precisión alta, superior al 95%.

A futuro se propone la construcción de nuevos modelos capaces de evaluar otras plantas de cereal básico, debido a su importancia en la seguridad alimentaria y a su vulnerabilidad ante el CC.

Referencias

- [1] Romero Padilla, A., Hernández Juárez, M., León Merino, A., & Sangermán-Jarquín, D. M. (2015). Impacto en el mercado mexicano de maíz en ausencia de políticas de producción de biocombustibles en Estados Unidos de América. *Revista mexicana de ciencias agrícolas*, 6(5), 1023-1033.
- [2] Organización de las Naciones Unidas para la Alimentación y la Agricultura. (FAO). (2018). Nota informativa de la FAO sobre la oferta y la demanda de cereales.
- [3] Instituto Nacional de Ecología y Cambio Climático. INEEC. (2018). Efectos del cambio climático. Lugar de publicación: Instituto Nacional de Ecología y Cambio Climático.
- [4] Cruz, Y. Y. P., & Martínez, P. C. C. (2015). Cambio climático: bases científicas y escepticismo. *CULCyT*, (46).
- [5] Montenegro, R. J. V., Zarabozo, O. D., & Baca, M. (2015). Modelos de impacto en la agricultura teniendo en cuenta los escenarios de la agricultura del cambio climático. *Revista Iberoamericana de Bioeconomía y Cambio Climático*, 1(1), 1-50.
- [6] Tonconi Quispe, J. (2015). Producción agrícola alimentaria y cambio climático: un análisis económico en el departamento de Puno, Perú. *Idesia (Arica)*, 33(2), 119-136.
- [7] López Feldman, A. J., & Hernández-Cortés, D. (2016). Cambio climático y agricultura: una revisión de la literatura con énfasis en América Latina. *El trimestre económico*, 83(332), 459-496.
- [8] CEPAL, N. (2015). La economía del cambio climático en América Latina y el Caribe: paradojas y desafíos del desarrollo sostenible.
- [9] Rodríguez, H. R. (2015). Cambio climático. El ine genera y pone a disposición del público la información más sólida y actualizada sobre las causas y efectos del cambio climático en México, 34.
- [10] Zárate-Malpica, A. H., & Miranda-Zambrano, G. A. (2016). Impacto del cambio climático en la seguridad alimentaria en zonas campesinas vulnerables de los Andes del Perú. *Revista mexicana de ciencias agrícolas*, 7(1), 71-82.
- [11] Canavese-Jardas, N. G. (2017). Cálculo del rendimiento de cultivos según la cantidad de agua empleada, a partir de modelos de simulación numérica. (Aplicación práctica a un proyecto de riego en Uruguay) (tesis de maestría). Universidad nacional autónoma de México, Ciudad de México, México.
- [12] Rojas-Lara, P. C., Pérez-Grajales, M., Colinas-León, M. T. B., Sahagún-Castellanos, J., & Avitia-García, E. (2008). Modelos matemáticos para estimar el crecimiento del fruto de chile manzano (*Capsicum pubescens* R y P). *Revista Chapingo. Serie horticultura*, 14(3), 289-294.
- [13] Reinoso, L., Martínez, R. S., Mercau, J., Gutierrez, M., & Otegui, M. E. (2018). Rendimiento potencial de maíz en los valles de

- Norpatagonia: una aproximación desde los modelos de simulación. *Instituto Nacional de Tecnología Agropecuaria*. Recuperado de https://inta.gob.ar/sites/default/files/inta_reinoso_potencial_maiz.pdf
- [14] Díaz-Pérez, Y., & Villalobos-Pérez, M. A. (2018). Validación del modelo AquaCrop en maíz (*Zea mays* L.) y sorgo (*Sorghum vulgare* L. Monech). *Revista Ingeniería Agrícola*, 8(2), 3-10.
- [15] Crotti, C., & Milera, S. (2006). Implementación del modelo cropsyst para la simulación del rendimiento del cultivo de maíz en una región argentina. *Centro de Investigación observación y monitoreo territorial y ambiental*, 2-4.
- [16] López-Seijas, T., Herrera-Puebla, J., González-Robaina, F., Cid-Lazo, G., & Chaterlán-Durruty, Y. (2009). Eficiencia de un modelo de simulación de cultivo para la predicción del rendimiento del maíz en la región del sur de La Habana. *Revista Ciencias Técnicas Agropecuarias*, 18(3).
- [17] Calibrado, I. (2014). Evaluación del modelo simdual kc para un cultivo de maíz en condiciones de secano en balcarce (Argentina).
- [18] López, H. E., Corral, J. A., de la Mora, O. C., Zarazúa, V. P., Durán, A. A., Vega, H. R. & Valle, M. A. (2014). Aplicación del modelo EPIC para evaluar el efecto del cambio climático y prácticas de manejo sobre el rendimiento de grano en maíz de temporal. *Revista Mexicana de Ciencias Agrícolas*, (10), 2007-2020. *Agrícolas*, (10), 2007-2020.
- [19] Manilla, A., & Salvagiotti, F. (2010). Validación del modelo Hybrid maize en condiciones óptimas de crecimiento. In IX Congreso Nacional de Maíz-17-19 noviembre.
- [20] López, C. I. (2002). Adaptación del modelo de crecimiento genérico SUCROS al ambiente Matlab, aplicación a un cultivo de maíz (híbrido HS-2). Tesis de maestría. Instituto Politécnico Nacional, Distrito Federal, México.
- [21] Gualdrón, D. J. & Neira, M. J. (2011). Entrenamiento de una red neuronal artificial para la clasificación de hojas asociadas al cultivo de maíz. *Revista Matices tecnológicos*, 3.
- [22] Barreno, M. D., Barrionuevo, J., & Misael, J. (2017). Diseño y construcción de un prototipo robotizado para el deshierbe automático en zonas planas de cultivos de maíz en su etapa inicial, a través de técnicas de visión artificial, para la asociación "Unión y Progreso" del cantón Pillaro, provincia de Tungurahua (Bachelor's thesis, Universidad de las Fuerzas Armadas ESPE Extensión Latacunga. Carrera de Ingeniería Mecatrónica.).
- [23] Irigoyen, A., Della Maggiora, A. I., & Angelocci, L. R. (2010). Redes neuronales artificiales para estimar el agua total en el suelo durante la estación de crecimiento de maíz. XIII Reunión Argentina y VI Latinoamericana de Agro meteorología, 20.
- [24] Caicedo, E.F. y López, J.A. (2009). Una aproximación práctica a las redes neuronales artificiales. Programa editorial, Universidad del Valle. ISBN 978-958-670-767-1
- [25] Gutiérrez, S. S. M., Palacios, A. T., Ruiz-Vanoye, J. A., & Pérez, S. O. L. (2018). Sustainable and technological strategies for basic cereal crops in the face of climate change: A literature review. *African Journal of Agricultural Research*, 13(5), 220-227.
- [26] Torres J, Landeros F, Enciso T, Sañudo M (2012). Phenological prediction models for white corn (*Zea mays* L.) and fall armyworm (*Spodoptera frugiperda* JE Smith). *Agrociencia (Montecillo)* 46(4):399-410
- [27] Sakamoto T, Gitelson A, Arkebauer T (2013). MODIS-based corn grain yield estimation model incorporating crop phenology information. *Remote Sens. Environ.* 131:215-231.
- [28] Lv H, Lei T, Huang X, Zhang Y (2015). Application of an Improved Grey Neural Network in Grain Yield Prediction.
- [29] Farjam A, Omid M, Akram A, Niari Z (2014). A neural network based modeling and sensitivity analysis of energy inputs for predicting seed and grain corn yields. *J. Agric. Sci. Technol.* 16(4):767-778
- [30] Matsumura K, Gaitan C, Sugimoto K., Cannon A, Hsieh W (2015). Maize yield forecasting by linear regression and artificial neural networks in Jilin, China. *J. Agric. Sci.* 153(03):399-410
- [31] Barrero O, Rojas D, González C, Perdomo S (2016). Weed detection in rice fields using aerial images and neural networks. In *Signal Processing, Images and Artificial Vision (STSIVA), Symposium.* IEEE 21:1-4.
- [32] Bose P, Kasabov N, Bruzzone L, Hartono R (2016). Spiking Neural Networks for Crop Yield Estimation Based on Spatiotemporal Analysis of Image Time Series. *IEEE Trans. Geosci. Remote Sens.* 54(11):6563-6573
- [33] Ravari S, Dehghani H, Naghavi H (2016). Assessment of salinity indices to identify Iranian wheat varieties using an artificial neural network. *Ann. Appl. Biol.* 168(2):185-194.
- [34] Goyal S (2013). Predicting properties of cereals using artificial neural networks: A review. *Sci. J. Crop Sci.* 2(7):95-115
- [35] Blömer, J., Lammersen, C., Schmidt, M., & Sohler, C. (2016). Theoretical analysis of the k-means algorithm—a survey. In *Algorithm Engineering* (pp. 81-116). Springer, Cham.