



Ciencias
de la
Computación

Ingeniantes

Predicción de heladas en cultivos usando redes neuronales en la zona de Salvatierra Guanajuato



Colaboración

Villaseñor Aguilar Marcos Jesús, Montecillo Puente Francisco Javier, Sámano Abone Obed Noé, Zuñiga Maldonado Walter Manuel, López Enriquez Renato, Instituto Tecnológico Superior de Salvatierra

Villaseñor-Aguilar Marcos-Jesús, M.C., Montecillo-Puente Francisco-Javier, Dr., Sámano-Abone Obed-Noé, M.C., Zuñiga Maldonado Walter-Manuel, M.E., López Enriquez Renato, ING., Instituto Tecnológico Superior de Salvatierra.

RESUMEN: Un sistema para la predicción de heladas para la región agrícola de Salvatierra, Guanajuato es presentado en este artículo. Este sistema se basa en una red neuronal que es entrenada usando algunas variables atmosféricas para la predicción de temperaturas. Luego, estas temperaturas son utilizadas para determinar posibles riesgos de daños a cultivos en la región. Particularmente, el trabajo se enfoca a especies comunmente cultivadas en la región, como son: ajo, lechuga, cebolla, col, coliflor, brócoli, frijoles, pepino, calabaza y zanahoria. La temperatura es utilizada como factor de prevención de riesgo, ya que en función de heladas es una de las variables que más dañan los cultivos. Los datos de entrenamiento para la red neuronal son obtenidos de tres estaciones meteorológicas que son parte del sistema del monitoreo meteorológico de la SAGARPA. El sistema es implementado en MATLAB para modelar la red neuronal y LABVIEW para el sistema de predicción de helada en los cultivos. La contribución principal de este artículo es el uso de técnicas de inteligencia artificial junto con registros meteorológicos a la agricultura, este tipo de agricultura es llamada actualmente agricultura precisión.

PALABRAS CLAVE: agricultura, red neuronal, variables atmosféricas.

ABSTRACT: This article outlines the prediction of temperatures for the agricultural region in Salvatierra, Guanajuato. Temperature is one of the major factors that affect crop production. The temperatures are predicted from a neural network trained with the following set of data: precipitation, minimum, average and maximum atmospheric temperature, average and maximum wind velocities, average direction of the wind, maximum solar radiation, relative humidity, evapotranspiration and potential evaporation. These temperatures are then used to determine possible risks in crop production in the region. Temperature predictions were carried out for the following produce: garlic, onions, lettuce, col, cauliflower, broccoli, cucumber, beans, zucchini and carrot. Raw data for training the neural network was obtained from three different meteorological stations within the SAGARPA Meteorological monitoring system. The neural network was modeled and implemented in MATLAB while the predictions of the temperatures in LABVIEW. This article contributes to the use of Artificial Intelligence (AI) techniques in agricultural precision.

KEYWORDS: agricultural, neuronal network, atmospheric variable.

INTRODUCCIÓN

Distintas técnicas se han empleado para el modelado de las variables climáticas. dichas variables permiten predecir heladas, sequías, lluvias en la distintas regiones. La importancia de predecir de manera oportuna las variables beneficia al sector agrícola.

En el sector agrícola las heladas provocan grandes pérdidas económicas en los distintos cultivos, dependiendo de su intensidad, momento de ocurrencia y fenología del cultivo, es decir, la etapa de desarrollo. De acuerdo a los factores agroclimáticos de la

región, las heladas son el principal factor que causa pérdidas económicas a la producción agrícola.

Es de gran relevancia en el proceso agrícola tener conocimiento del comportamiento de los parámetros climáticos como radiación, temperatura, humedad relativa, precipitaciones, entre otros. Estos parámetros son utilizados para la toma de decisiones en el sistema agropecuario [1]. Grandes variaciones en estos parámetros ocasionan problemas en el sector, sin embargo, logrando conocer de manera anticipada el comportamiento de estos permite solucionarlos y obtener una agricultura rentable. Por ejemplo, los invernaderos tratan de controlar algunas de estas variables para que exista producción continua de algunas especies. En la producción abierta es complicado lograr esto, en particular, realizar previsiones para la lucha activa frente al fenómeno de helada es un gran reto [1][3].

Se han desarrollado trabajos sobre las predicciones de variables climáticas. Uno de los trabajos de referencias es el desarrollado por Ovando [5]. El trabajo consistía en modelo en una Red Neuronal Artificial (RNA) del tipo Backpropagation para predecir días helados. El modelo emplea la temperatura, humedad relativa, nubosidad, dirección y velocidad del viento. Riabani [9]. desarrolló una máquina de aprendizaje. Conjuntamente utilizó un algoritmo propuesto por Huang para una Red Neuronal Artificial (RNA) monocapa con propagación hacia adelante. La RNA se enfocaba en la predicción temprana de heladas de la Cochabamba Bolivia tomando datos de 6 estaciones meteorológicas. González [8]. Propuso un modelo de predicción evapotranspiración basado en una RNA feed-forward backpropagation. El modelo constaba con cuatro neuronas en la capa intermedia y una neurona en la capa de salida. Para lograr predecir la evapotranspiración emplea la temperatura del aire, la radiación solar, la humedad relativa y la velocidad del viento.

Para la prevención de heladas existen técnicas que analizando las variables climáticas permiten predecir el comportamiento y llegada de estas. Entre las técnicas para este propósito existen tales como estadística inferencial, modelos caóticos, técnicas de inteligencias artificial entre otros.[1][5]. Las técnicas de la inteligencia artificial han logrado ser de gran utilidad para la predicción de modelos, identificación de patrones, clasificación e identificación de objetos, por mencionar algunos casos, [2]. En este trabajo se utiliza una técnica ampliamente conocida llamada redes neuronales para la predicción de clima.

Las redes neuronales computacionales son modelos simplificados de los biológicos. Estos modelos son conocidos como Redes Neuronales Artificiales (RNA). Las RNA tratan de emular las capacidades del cerebro para resolver ciertos problemas de visión, reconocimientos de patrones o control. En la Figura 1 se puede observar la representación esquemática de una RNA también llamada neuro-computadora, red conexionista o procesador paralelo distribuido. La definición de las RNA según Haykin es

un procesador paralelo distribuido y masivamente interconectados que almacena conocimiento experimental [4]. Las RNA presentan las características siguientes: forma de adquirir el conocimiento experimental y los pesos de interconexión (sinapsis) que varían constantemente [4] [7].

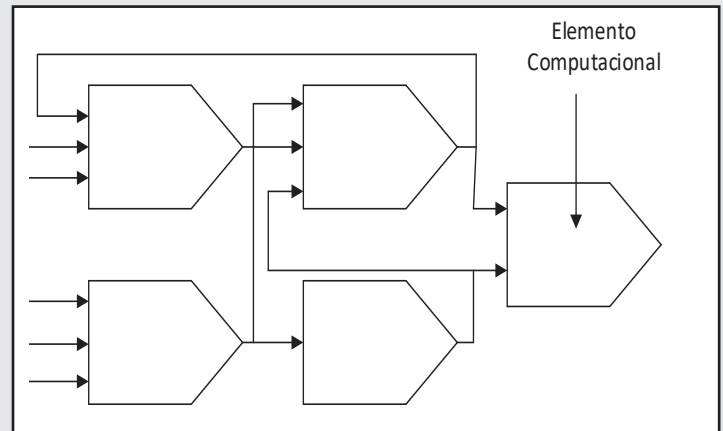


Figura 1.- Representación de una RNA

Las RNA ofrecen las siguientes ventajas: a) No linealidad, el procesador neuronal es básicamente no lineal y, por consecuencia, la RNA también. Los modelos climáticos son no lineales y algunas llegan a ser caóticos. b) Transformación entrada-salida, el proceso de aprendizaje consiste básicamente en presentar a la red un ejemplo y modificar los pesos sinápticos de acuerdo su respuesta. Esto permite adaptarse al comportamiento de muchos sistemas, por ejemplo de predicción de clima local. c) Adaptabilidad, La red tiene la capacidad de adaptar los parámetros, aun en tiempo real. d) Tolerancia a fallas, debido a la interconexión masiva, la falla de un procesador no altera permanentemente la operación. e) Uniformidad en el análisis y diseño. Esto permite garantizar características precisas de funcionamiento. Las RNA utilizan el perceptrón que es el modelo de neurona más simple, una representación del perceptrón se muestra en la Figura 2.

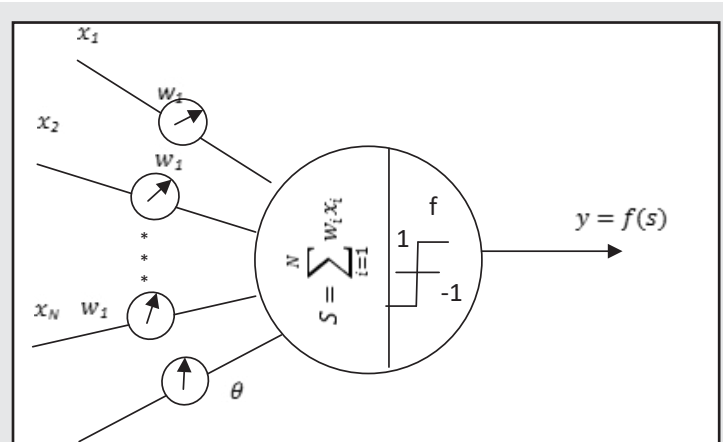


Figura 2. Modelo del perceptrón: X_i señales de entrada, W_i pesos, S podenración del perceptrón, f función de activación, [17][18].

Las RNA se distinguen por tener al menos una o varias capas ocultas como se muestra en la Figura 3. Estas redes presentan la ventaja de resolver problemas complejos, tales como sistemas de predicción, modelos no lineales [18]. Las redes neuronales requieren de entrenamiento supervisado o no supervisado que consiste en utilizar datos de entrada y salida que definen el comportamiento del sistema. Una vez entrenada la red neuronal solo se evalúa la red y esta entrega las salidas correspondiente del sistema para la cual fue entrenada.

Las diferentes especies tienen rangos de temperatura bien definidos para que estas no se vean afectadas, sea en su crecimiento o en su daño total. Un sistema de predicción de riesgo de especies en agricultura está compuesto por una RNA y la toma de decisión de riesgo de alguna especie particular.

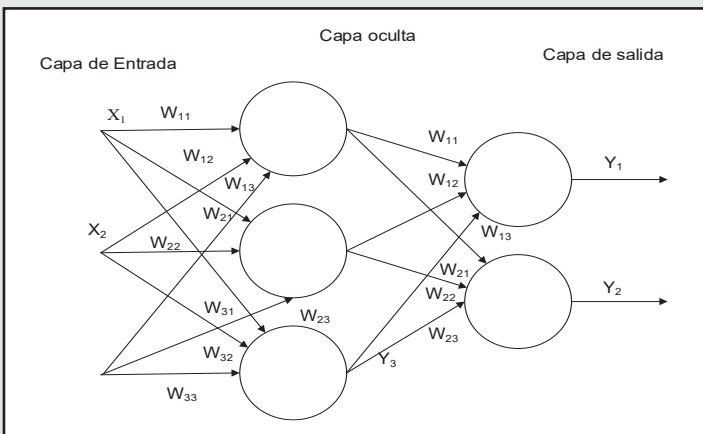


Figura 3. Arquitectura de una red neuronal multicapa

La contribución principal en este trabajo es el uso de variables meteorológicas para entrenar una red neuronal en la predicción de heladas en la zona de Salvatierra. Particularmente para cultivos de ajo, lechuga, cebolla, col, coliflor, brócoli, frijoles, pepino, calabaza y zanahoria. Además, del uso de las estaciones meteorológicas de monitoreo en tiempo real de la SAGARPA en la zona y la toma de decisiones sobre el riesgo en cultivos.

El contenido del artículo se organiza como sigue, en las siguientes secciones se muestran la metodología empleada y los materiales empleados. Además, se presenta la validación de las técnicas utilizadas, el sistema de predicción y toma de decisiones de riesgo, finalmente se presentan la discusión y conclusiones finales.

MATERIALES Y MÉTODOS

En esta sección se presenta la metodología empleada y los materiales para la implementación del sistema de predicción de heladas. Un diagrama de bloques de las diferentes etapas del sistema se muestra en la Figura 4.

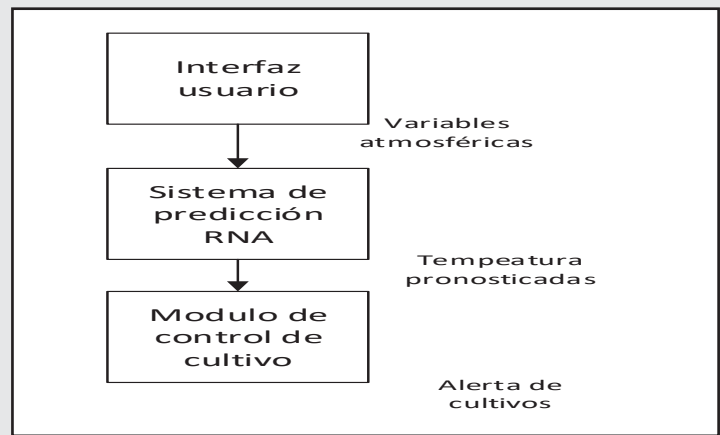


Figura 4. Diagrama de bloques del sistema: a) Interfaz de usuario desarrollada en Matlab®, b) Sistema de predicción desarrollada Matlab®, c) Módulo de control de cultivo desarrollado en Labview®.

El primer bloque es la interface de usuario, es el medio a través del cual se proporcionan los valores de las variables meteorológicas: precipitación total, velocidad del viento máxima, dirección de la velocidad máxima del viento, velocidad promedio del viento, dirección promedio del viento, radiación global, humedad relativa, evapotranspiración de referencia, evaporación potencial. El segundo bloque es el sistema de predicción RNA de temperaturas, es un módulo que se utiliza para pronosticar o predecir las condiciones futuras de temperatura utilizando las entradas de la interfaz de usuario. Por último, el tercer bloque es una aplicación en Labview® que genera alertas. Estas permiten determinar que cultivos se pueden dañar de acuerdo a la predicción generada por la red neuronal.

1. RECOPIACIÓN DE DATOS METEOROLÓGICOS

Los datos de las variables meteorológicas para el entrenamiento de la red neuronal fueron obtenidos de las estaciones meteorológicas El Sabino, El Cubo y Huatzindeo. La ubicación en Salvatierra de estas se muestran en la Figura 5.

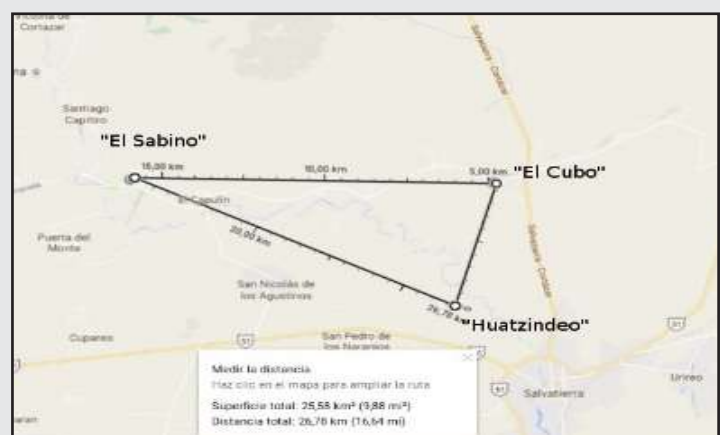


Figura 5. Ubicación de las estaciones meteorológicas

En conjunto de datos entrenamiento para la red neuronal se obtuvieron de las estaciones meteorológicas de los años 2006 al 2015. El pre-procesamiento de estos sigue las etapas mostradas en la Figura 6.

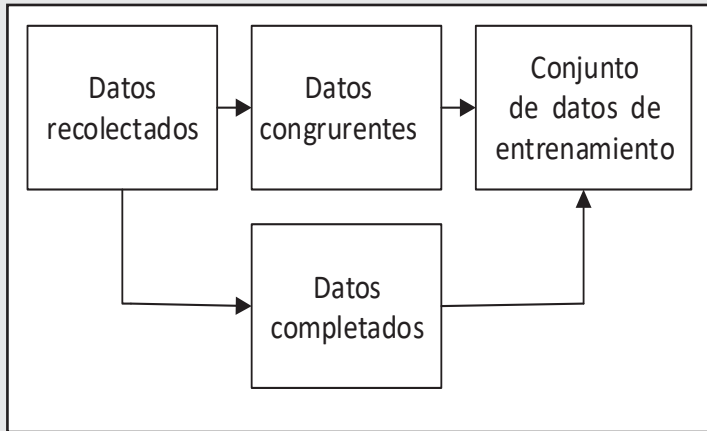


Figura 6. Pre-procesamiento de datos: a) Datos recolectados b) Datos congruentes, c) Datos completados, d) Conjuntos de datos de entrenamiento.

El primer bloque consiste en la recolección de datos de las estaciones meteorológicas; El Sabino; El Cubo y Huatzindeo. El bloque de datos congruentes consiste en revisar que tuvieran la mayor cantidad de variables de las mediciones de requeridas, es decir que no faltaran registros. El bloque de datos completado, consiste en completar los registros faltantes. Estos se completaron con la información proporcionada por la estación meteorológica del INIFAP ubicada en Celaya, Gto. A una distancia de 50 Km a Salvatierra. El bloque final, consiste en formar el conjunto de entrenamiento con registros completados y escalados a un rango de (-1, 1). El escalamiento es requerido ya que facilita el aprendizaje de la red. Los datos registrados, se dividen en dos partes, los datos de entrada y datos de salida a la red. Los datos de entrada corresponden a las variables de un día particular y los datos de salidas consisten en las temperaturas registradas dos días después.

2. ENTRENAMIENTO DE RED NEURONAL

En esta sección se presenta la metodología empleada para el desarrollo de la red neuronal. Además, se analiza la respuesta del entrenamiento de la red neuronal variando algunas de las características, principalmente la cantidad de neuronas en la capa oculta. Lo anterior con la finalidad de elegir la mejor configuración de red posible.

El esquema de entrenamiento utilizado, se muestra en la Figura 7. La entrada u del modelo es comparada con la salida \tilde{u} de la RNA. Con el error obtenido por la resta entre \tilde{u} y y se realiza el ajuste de los pesos de todas las capas de la RNA mediante el empleo del algoritmo de aprendizaje PROBABILISTIC [7]. El ajuste de los pesos se realiza de manera iterativa con todo el conjunto de

datos de entrenamiento para que el modelo de predicción tenga una adecuada respuesta. El aprendizaje de la red depende del conjunto de entrenamiento, entre mayor sea el conjunto de entrenamiento, la red tendrá una mejor respuesta, es decir, su comportamiento se asemejará en mayor medida al modelo real.

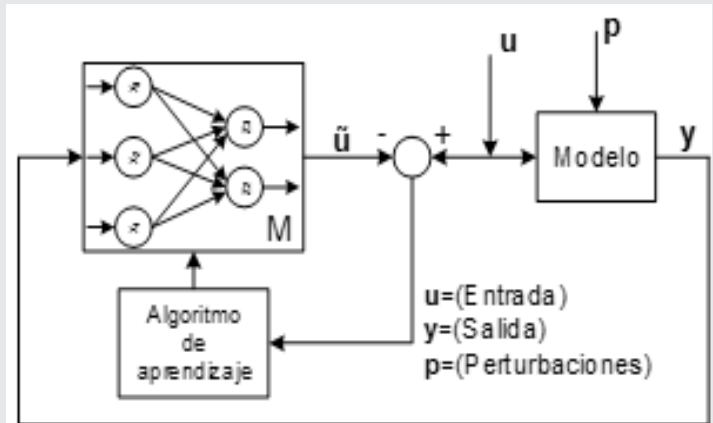


Figura 7. Esquema de entrenamiento del modelo.

La importancia de la RNA backpropagation consiste en su capacidad de autoadaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe entre un conjunto de patrones dados como ejemplo y sus salidas correspondientes [5].

En la Tabla 1, se muestran los resultados obtenidos del entrenamiento de las cuatro propuestas de modelos de predicción de heladas usando RNA. Para el modelo de predicción la propuesta 2 es la que tiene el menor error de los modelos. La RNA de 50 neuronas en la capa oculta 1 y 2 será empleada para el desarrollo del sistema de predicción de heladas. Esta RNA presenta el error mínimo de 0.00145 en el entrenamiento. Para este propósito se empleo el Toolbox de redes neuronales de Matlab.

Tabla 1. Redes neuronales entrenadas

Red	Entradas	Capa oculta 1	Capa oculta 2	Salida	Error
Modelo 1	24	100	-	3	0.00340
Modelo 2	24	50	50	3	0.00145
Modelo 3	24	25	25	3	0.00555
Modelo 3	24	35	35	3	0.00338

Los resultados del entrenamiento se presentan en el histograma de la Figura 8, se muestra el error entre el valor de salida de la RED y el valor real. El eje horizontal muestra intervalos de error. El eje vertical indica cuantos registros de prueba caen en un intervalo error específico. La canti-

dad de datos de entrenamiento de entrada y salidas fueron 3096, con dimensionalidad 7 y 3, respectivamente.

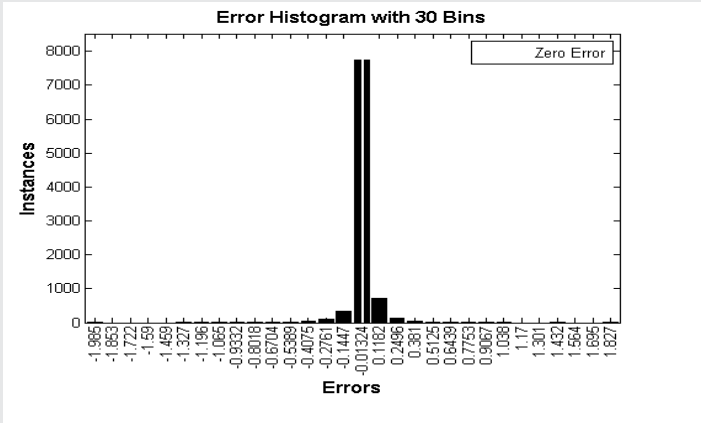


Figura 8. Histograma de error de entrenamiento de la RNA de predicción de heladas. Esté histograma muestra los errores de los tres datos de salida juntos, 3x 3096 datos.

3. VALIDACIÓN DE RED NEURONAL

Registros de los meses Enero a Mayo del 2016, corresponden a 150 registros de todas las variables involucradas, fueron utilizados para la validación del entrenamiento de la RNA. Después de introducir estos datos a la red entrenada se obtuvo un error cuadrático medio de 0.15 aproximadamente. El histograma de error para estos datos se muestran en la Figura 9.

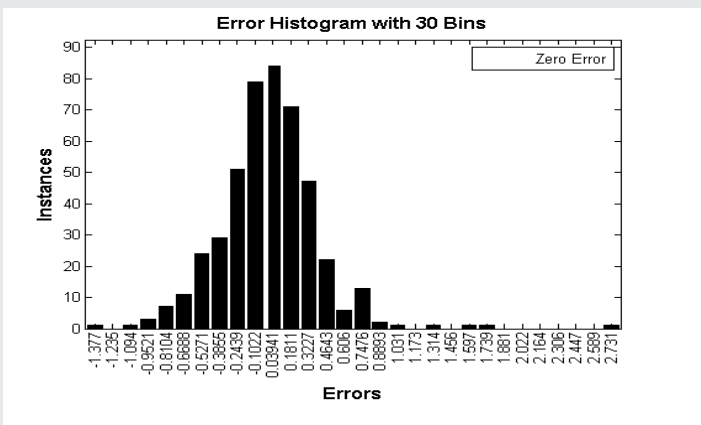


Figura 9. Histograma de error de validación de la RNA de predicción de heladas usando datos del 2016 del periodo Enero-Mayo.

Las gráficas de predicción del sistema con los datos antes mencionados se presentan en la Figura 10. Las gráficas corresponden a las tres temperaturas (Temperatura máxima, Temperatura mínima, Temperatura media); se puede observar que la predicciones siguen a las temperaturas reales. Sin embargo, también se pueden observar variaciones pronunciadas en algunos puntos, estos se podrían reducir entrenando la red de manera continua utilizando los datos recientes de las estaciones meteorológicas.

1. INTERFAZ DE PREDICCIÓN DE HELADA

El sistema para predicción de heladas utiliza una aplicación en Labview que permite identificar el estado al que se encontraran expuestos los cultivos. Para este fin, las variables meteorológicas actuales son ingresadas a la RNA que hace una predicción de dos días de anticipación de las temperaturas máximas, mínimas y medias.

Estas temperaturas son ingresadas al módulo de control de cultivo, que arroja alerta sobre las posibles heladas que pueden perjudicar los diferentes cultivos. En la Tabla 2 se muestran las temperaturas críticas con las que se pueden dañar un tipo de cultivo particular.




Figura 10. Gráficas comparativas de la temperatura real contra la temperatura RNA. La línea continua es la temperatura real y la línea punteada es la temperatura pronosticada. a) La grafica superior representa la temperatura máxima, b) La grafica intermedia representa la temperatura mínima, c) La grafica inferior representa la temperatura máxima.

La interfaz tiene como objetivo ingresar los parámetros de la Tabla 2 con las temperaturas críticas para cada cultivo. y con los rangos de temperatura específicos para cada cultivo. Además, determina si el cultivo se encuentra en la fase detención vegetal, germinación, floración, desarrollo y maduración. A continuación se muestra la Figura 11 y en la que se muestra el icono del SubVi (aplicación en LabView), el panel frontal y el diagrama de programación gráfica que contiene.

RESULTADOS Y CONCLUSIONES

El modelado de fenómenos meteorológico se manifiesta como un proceso no lineal por la involucrar gran cantidad de variables dependientes, cuya función de ellas no se conocen. La aplicación de modelos no lineales hace factible el uso de las RNA [5]. A diferencia de modelos tradiciones que la estadística.

Los resultados obtenidos muestran que se tiene un sistema de predicción bueno considerando que el clima es un sistema caótico. Para tener resultados reales y actuales del sistema completo, sería conveniente supervisar los diferentes cultivos durante una ventana de temporal a partir de ahora e ir actualizando el sistema de predicción con los nuevos registros que obtengan.

Tabla 2. Rango de temperatura de cultivos proporcionadas por Infoagro.

Cultivo	Temperatura de daños de cultivo C°		Temperaturas óptimas de desarrollo C°	
	Mínima	Máxima	Mínima	Máxima
Ajo	-1	40	10	34
Brócoli	2	30	20	24
Calabacín	0	35	25	30
Cebolla	-1	25	16	22
Col	8	30	18	20
Coliflor	0	27	15	22
Frijol	2	35	20	30
Lechuga	-6	30	14	20
Pepino	1	30	20	30
Zanahoria	-5	28	16	18

En la siguiente tabla se presenta un análisis comparativo del modelo reportado en la literatura versus el propuesto en este trabajo. En los modelos propuestos Ovando et al. tiene como variables de entrada temperatura a nivel del abrigo (Ta), humedad relativa (Hr), temperatura a punto de rocío (Tr), dirección del viento (DV), velocidad del viento (VV) y nubosidad (N). Se seleccionó el modelo M1 que tiene las siguientes características: 15 neuronas en la capa de entrada, 15 en la capa oculta, un error de validación de 1 y sus días con error son 2.27 días.

En el segundo modelo M2 emplea todas las variables excepto la humedad relativa. El modelo cuenta con 13 neuronas en la capa de entrada, 7 en la capa oculta, un error de validación de 7.5 y sus días con error son 1.87 días.

El tercer modelo M3 propuesto por López emplea como entrada la temperatura media del aire (Tamed), radiación solar (Rg), velocidad media del viento (VV-med). La RNA cuenta con 4 neuronas en la capa de entrada, 1 en la capa oculta y 4.

En la comparativa presentada en la Tabla 3, se puede observar que existen trabajos parecidos que emplean las variables meteorológicas. Pero no incluyen algunos componentes adicionales como en el modelo propuesto en este trabajo. La ventaja que presenta integra un módulo de decisiones de heladas y prevención para el daño de cultivos en la zona de Salvatierra, Guanajuato.



PANEL




Figura 9. Histograma de error de validación de la RNA de predicción de heladas usando datos del 2016 del periodo Enero-Mayo.

Los resultados obtenidos muestran que se tiene un sistema de predicción bueno considerando que el clima es un sistema caótico. Para tener resultados reales y actuales del sistema completo, sería conveniente supervisar los diferentes cultivos durante una ventana de temporal a partir de ahora e ir actualizando el sistema de predicción con los nuevos registros que obtengan. Además, de tener contacto directo con los agricultores sobre sus cultivos.

Tabla 3. Rango de temperatura de cultivos proporcionadas por Infoagro.

Modelo	M1 Ovando (2005)	M2 Ovando (2005)	M3 González (2011)	Propuesto
Predicción	heladas	Heladas	Evotranspiración	Temperatura para decisión de heladas
Variables entrada	Ta, Hr, Tr, Dv, Vv, N	Ta, Tr, DV, VV, N	Ta, Tr, DV, VV, N	T, Hr,, Dv, Vv, N
Capa entrada	15	13	4	24
Capa oculta 1	15	7	4	50
Capa oculta 2	-	-	-	50
Criterio de validación (Error Cuadrático)	1.0 días	7.5 días	-	0.00145 Temperatura
Descripción del funcionamiento del modelo.	El modelo pronostica los días de heladas	El modelo pronostica los días de heladas	El modelo pronostica los días de heladas -	El modelo pronostica la temperatura e involucra un módulo de decisión para las heladas

REFERENCIAS

- [1] García, F., Sostillo, C., Casagrande, G., Vergara, G. (2015). Caracterización de régimen de heladas en Aguil, Provincia de la Pampa (Argentina). SEMIDIARIA Revista de la Facultad de Agronomía UNLPam, 17-23.
- [2] Madrid, C.M., (2016). Las Matemáticas del cambio climático. Noviembre, 9, 2016, Universidad Complutense de Madrid.
- [3] Mercado, F., Fernandez, W., Herrera, J. (2016). Sistema de inteligencia artificial para la predicción temprana de heladas meteorológicas. Acta Nova, 483-489.
- [4] Hykin Simon, Neural Networks and Learning Machines (2013) (3 ed.).
- [5] Ovando, G., Bocco, M., & Sayago, S. (2005). Redes neuronales para modelar la predicción de heladas. Agricultura Técnica, 66-72.
- [6] Ramirez A., A., Gadea G., R., Colom P., R., (2008). Diseño y experimentación de un cuantizador vectorial hardware basado en redes neuronales para un sistema de codificación de video. (Tesis Doctoral). C.C. De Universidad Politécnica de Valencia.
- [7] Vlacic, V., (2016). Summary of the training functions in Matlab's NN toolbox. Noviembre, 9, 2016, http://alumni.cs.ucr.edu/~vladimir/cs171/nn_summary.pdf
- [8] González-Camacho J.M., R. Cervantes, W. Ojeda, e I. López, predicción de la evapotranspiración de referencia mediante redes neuronales artificiales.", , ingeniería hidráulica en México , Vol.1, 2008, pp.127-139
- [9] Riabani Mercado F., García Fernandez W., Herrera Acebey J., Sistema de inteligencia artificial para la predicción temprana de helada meteorológicas.", RevActaNova , Vol.7, 2016, pp.483-495.