

# IoT-based Spatial Monitoring and Environment Prediction System for Smart Greenhouses

Carlos A. Hernández-Morales , J.M. Luna-Rivera , F. Villarreal-Guerrero , P. Delgado-Sanchez   
and Zoe A. Guadiana-Alvarado 

**Abstract**—Agriculture has seen several technological transformations in recent years, allowing accelerated growth in production to meet the greater consumer demand for food. In particular, the adoption of the internet of things (IoT) is rapidly transforming the future of agriculture. In this paper, we present a data-driven climate prediction model for greenhouses using an effective and low-cost IoT-based spatial monitoring system. The IoT infrastructure comprises four stages: data gathering, transmission, analysis and processing of information, and visualization. This system was deployed and tested in a real greenhouse for three months, monitoring the temperature, relative humidity, and CO<sub>2</sub> levels. The behavior of these environmental variables were predicted 24h in advance, obtaining an advantage in prediction accuracy. Additionally, we developed a spatial monitoring strategy based on packing density theory as a solution to the climate variability within greenhouses, offering a compromise between effectiveness and cost.

**Index Terms**—Climate prediction, Internet of things, LPWAN, Machine Learning, Precision agriculture, Smart greenhouse

## I. INTRODUCCIÓN

El crecimiento de la población mundial, así como el cambio climático actual, han transformado la cosecha de cultivos bajo ambientes controlados en un tema de interés para el desarrollo tecnológico y la innovación [1]. La agricultura protegida es un conjunto de técnicas que tienen por objetivo resguardar los cultivos de los efectos impuestos por los fenómenos climáticos, además de ofrecer condiciones ambientales óptimas para su mejor desarrollo [2]. Entre sus principales ventajas se encuentra cultivar alimentos fuera de su ciclo natural y en un tiempo más corto, reducir la presencia de plagas y enfermedades, así como mejorar el rendimiento y calidad de los cultivos. Sin embargo, mantener las condiciones ideales dentro de los invernaderos es complicado, esto debido a los muchos factores que influyen en el desarrollo de los cultivos. Dentro de los parámetros ambientales que tienen mayor impacto en el crecimiento de las plantas se encuentran la temperatura, la humedad relativa, los niveles de dióxido de carbono (CO<sub>2</sub>) y la intensidad de luz [3]–[5]. La temperatura es el factor que tiene mayor impacto en las fases del desarrollo de las plantas, ya que esta tiene una relación directa con sus procesos fisiológicos. Por su parte, los valores extremos de la humedad contribuyen directamente a problemas como

enfermedades en las raíces y hojas, estrés de la planta, pérdida de calidad, entre otros. Por otro lado, el CO<sub>2</sub> es un gas natural que aporta a las plantas la energía necesaria para su desarrollo. Si existe una concentración muy baja de CO<sub>2</sub> los cultivos no tendrán un proceso de fotosíntesis adecuado, afectando su crecimiento, desarrollo y floración. Finalmente, la luz es otro factor que influye directamente en el proceso de fotosíntesis de las plantas. Con un exceso de luz directa, la temperatura aumenta, la transpiración de la planta aumenta, y por ende, aumenta la demanda de riego.

Durante los últimos años han surgido nuevos enfoques alrededor de este sector como son la agricultura de precisión y la agricultura inteligente, los cuales contemplan la integración de distintas tecnologías a diferentes niveles en los campos agrícolas. Esto con el objetivo de mejorar tanto la cantidad como la calidad de los cultivos, además de ofrecer una mejor gestión del uso de los recursos agrícolas [6], [7]. Para esto, se necesitan desarrollar sistemas que sean capaces de monitorear en tiempo real, recopilar y procesar las grandes cantidades de datos provenientes de los campos. En este aspecto, conceptos como el Internet de las cosas (IoT, por sus siglas en inglés) y los modelos predictivos de aprendizaje automático (Machine Learning) se presentan con el potencial de contribuir en el desarrollo de una agricultura inteligente, entregando información que puede ayudar a los agricultores a tomar mejores decisiones con relación a la planificación de distintas actividades que incluyen las acciones de control del clima, la aplicación de tratamientos, gestión de recursos, entre otras [8], [9].

## II. TRABAJO RELACIONADO

Actualmente, se han estado realizando diversos estudios acerca de la aplicación de distintas tecnologías en los campos agrícolas como son el uso de sensores, robots, IoT, algoritmos de Machine Learning, Big Data, entre algunas otras. Como ejemplo de ello, en [9] y [10] se presenta un análisis del impacto de este tipo de tecnologías en el desarrollo de la agricultura del futuro. También se han realizado trabajos en donde se aplican diversas tecnologías en áreas de la agricultura tales como los sistemas de riego, monitoreo, predicción y control del clima, detección de plagas y enfermedades, rendimiento de la cosecha, entre muchas otras [11]–[20]. Esto utilizando diferentes tecnologías de comunicación como las redes de corto alcance (Wi-Fi, Zigbee, Bluetooth), las redes celulares (GPRS, GSM, LTE), arquitecturas híbridas, y, más recientemente, las redes de baja potencia y área amplia (LPWAN, por sus siglas en inglés) donde tecnologías como

C.A. Hernández-Morales, J.M. Luna-Rivera, P. Delgado-Sanchez and Z.A. Guadiana-Alvarado are with the Autonomous University of San Luis Potosí, Mexico. E-mail: a286550@alumnos.uaslp.mx, mlr@uaslp.mx, pablo.delgado@uaslp.mx, arturo.guadiana@uaslp.mx. F. Villarreal-Guerrero is with the Autonomous University of Chihuahua, Mexico, E-mail: fvillarreal@uach.mx

LoRaWAN, Sigfox y NB-IoT son las más utilizadas. Por otro lado, existe un creciente interés por el desarrollo de pruebas de conceptos de los sistemas de monitoreo IoT, en su mayoría compuestos por tres etapas (monitoreo, comunicación y aplicación) [21]–[24].

Adicionalmente, existen trabajos en los cuales se ha explorado la aplicación de diversas técnicas de Machine Learning al campo de la agricultura inteligente, en su mayoría utilizando modelos basados en las redes neuronales artificiales (ANN, por sus siglas en inglés). Ejemplo de ello es la predicción del comportamiento de diferentes variables ambientales dentro de los invernaderos [25]–[27]. En [25] se presenta un predictor para la temperatura bajo el concepto de Edge computing. Para el desarrollo de dicho predictor se siguen tres arquitecturas: ANN, red neuronal recurrente simple (RNN, por sus siglas en inglés) y una RNN basada en el modelo Long Short-Term Memory (LSTM). La eficiencia de los predictores fue probada con los datos obtenidos del monitoreo durante 6 meses. Los resultados obtenidos muestran valores de predicción con 10 minutos de anticipación. Entre las conclusiones relevantes se encontró que la solución con mejor relación rendimiento-complejidad es el modelo ANN. Existen también otros trabajos en los cuales se utilizan técnicas de Aprendizaje Automático para diferentes aplicaciones en la agricultura como la clasificación de enfermedades de los cultivos, la generación de alertas, predicción del crecimiento de plantas, entre otros [28]–[30].

Existen algunos esfuerzos para desarrollar soluciones capaces de entregar información suficiente para conocer la variabilidad del clima dentro de los invernaderos. Por ejemplo, las soluciones basadas en la implementación de redes de sensores inalámbricas (WSN, por sus siglas en inglés). Algunas de estas soluciones se basan en colocar un número aleatorio de sensores en diferentes puntos dentro de un invernadero [31]–[33]. Más recientemente, en [34], los autores hacen un esfuerzo para determinar la ubicación, así como el número óptimo de sensores dentro de un invernadero, esto desplegando un total de 9 nodos capaces de medir valores de temperatura y humedad. De estos 9 sensores se seleccionan diferentes combinaciones con un número diferente de nodos y se realiza un análisis basado en la prueba y error, y de entropía, esto para encontrar la combinación de nodos que mejor represente el clima dentro del invernadero. De manera similar, en [35] se presenta una metodología basada en el algoritmo de muestreo de Thompson para encontrar la distribución óptima de los sensores dentro de un invernadero. Esto utilizando un total de 56 nodos capaces de medir valores de temperatura y humedad, estos son distribuidos de manera uniforme dentro del invernadero.

A pesar de los recientes avances en el desarrollo tecnológico alrededor del concepto de IoT, estas soluciones aún están en sus primeras etapas, teniendo diversos retos que impiden la adopción de este tipo de soluciones a diferentes niveles de la agricultura. Uno de los problemas importantes a combatir es la variabilidad del clima dentro de los invernaderos, lo cual tiene un fuerte impacto en la productividad. Otro problema es el costo, la mayoría de los sistemas desarrollados para la agricultura inteligente tienen un alto precio, son complejos y

con falta de claridad en cuestión al costo-beneficio que puede suponer para los agricultores. La contribución principal de este trabajo se centra en el desarrollo, implementación y evaluación de un sistema IoT práctico y de bajo costo para el monitoreo en tiempo real y predicción del ambiente en invernaderos inteligentes. Este sistema, en comparación con los presentados en el estado del arte actual, introduce una metodología clara y escalable que permite definir un compromiso entre el número mínimo de dispositivos IoT para el monitoreo espacial del clima en un invernadero y su precisión. Asimismo, se integra un modelo de predicción climática para invernaderos que garantiza el crecimiento estable y una producción de cultivos con un alto rendimiento. El despliegue de la prueba de concepto de este sistema se llevó a cabo en un invernadero en México durante tres meses realizando el monitoreo de las variables ambientales de temperatura, los niveles de humedad y CO<sub>2</sub>.

El resto del manuscrito tiene la siguiente estructura. La Sección III describe de manera breve cada uno de los componentes que conforman la arquitectura del sistema IoT. Los detalles de la infraestructura, así como del desarrollo e implementación del sistema IoT en un invernadero real se muestran en la Sección IV. En la Sección V se presentan y discuten los resultados obtenidos validando la efectividad del sistema IoT. Por último, la Sección VI presenta las conclusiones de este trabajo.

### III. MODELO DEL SISTEMA IOT

Los cambios en los patrones climáticos derivados del calentamiento global actual afectarán el desarrollo y los procesos fisiológicos de los cultivos, por lo cual se espera un aumento en las demandas hídricas. Por esta razón se necesita mejorar las capacidades de los invernaderos para combatir estos efectos, especialmente en los casos de los invernaderos de baja y media tecnología. Por lo anterior, se han propuesto varias arquitecturas o modelos conceptuales para los sistemas IoT en la literatura [36]–[38]. Sin embargo, no existe una arquitectura de referencia estándar para IoT. Para este trabajo se utiliza una arquitectura por capas flexible para la implementación del sistema de monitoreo IoT en tiempo real con aplicación en invernaderos, ver Fig. 1. Esta arquitectura está compuesta por cuatro capas en donde los datos fluyen desde los sensores conectados a los dispositivos IoT, a través de una red, que posteriormente son enviados a la nube para su procesamiento, análisis y almacenamiento y, finalmente, visualizados mediante una interfaz de usuario final. Este diseño tiene el objetivo de ofrecer un compromiso entre la efectividad y el costo, con una estructura modular la cual permite la adopción de diferentes tecnologías, lo que hace que el sistema pueda incrementar su nivel tecnológico y escalamiento de manera gradual.

**Capa de percepción.** Esta primera capa es en la que se encuentran los sensores y los módulos de comunicación encargados de captar los datos sobre el estado de un proceso, en este caso las condiciones ambientales dentro del invernadero, el cual debe ser monitoreado continuamente y en tiempo real para asegurar que las condiciones sean las óptimas para el correcto desarrollo de los cultivos. Este trabajo considera la

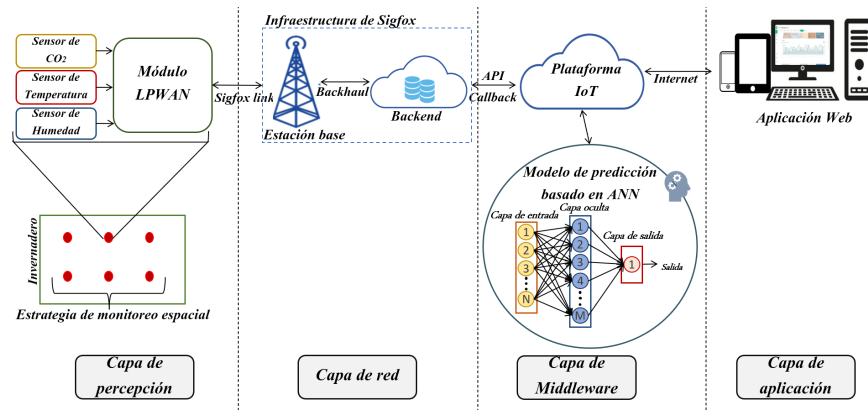


Fig. 1. Arquitectura de referencia para el desarrollo del sistema de monitoreo IoT.

adquisición de la temperatura, la humedad relativa y los niveles de  $CO_2$  mediante la construcción de un dispositivo IoT.

**Capa de red.** Esta capa es la encargada de llevar a cabo la comunicación entre los dispositivos IoT y las plataformas en la nube. Para esto, se pueden utilizar diferentes estándares de comunicación como redes inalámbricas de corto alcance, que ofrecen una cobertura muy restringida, o redes de largo alcance como las redes celulares que son muy complejas y costosas. Sin embargo, actualmente han surgido nuevos esquemas de comunicación que ofrecen mejores características para las comunicaciones machine-to-machine (M2M) y los dispositivos IoT, estas son llamadas redes LPWAN, donde las tecnologías de LoRaWAN, Sigfox y NB-IoT están entre las más utilizadas hoy en día para el desarrollo de soluciones IoT. La conectividad de los dispositivos IoT que componen el sistema de monitoreo que se propone en este trabajo se lleva a cabo a través de la red de Sigfox, aunque es importante resaltar que el modelo del sistema IoT propuesto permite utilizar otro tipo de tecnología LPWAN.

**Capa de middleware.** La capa de middleware o procesamiento toma un papel muy importante, ya que en ella se pueden definir servicios en los cuales se lleva a cabo el almacenamiento, procesamiento y análisis de los datos necesario que pueda ayudar a optimizar la producción y mejorar la calidad de los cultivos, esto a través del conocimiento de la variabilidad del clima y de las predicciones de este. En esta capa se integra como servicio un componente de aprendizaje en el cual se definen algoritmos de Machine Learning, de manera que la información recolectada por los dispositivos pueda ser procesada y analizada a través del tiempo, realizando predicciones de las condiciones del ambiente dentro del invernadero.

**Capa de aplicación.** En esta última capa se tiene la interfaz de usuario o aplicación que permite el monitoreo, visualización e interpretación de los datos del invernadero. En este caso, se presenta el desarrollo de una aplicación web simple con el propósito de que el usuario pueda tener acceso a la información generada por el sistema, ya sea en tiempo real o realizando consultas de datos históricos, esto a partir de cualquier dispositivo que tenga acceso a internet.

#### IV. IMPLEMENTACIÓN Y DESPLIEGUE DEL SISTEMA IOT

Como prueba de concepto el sistema IoT se implementó en el Laboratorio de producción vegetal protegida que pertenece al área Agroindustrial de la Facultad de Ingeniería de la Universidad Autónoma de San Luis Potosí, México. Este es un invernadero de tipo túnel sin cenital con un área de  $60m^2$ , teniendo una longitud de  $12m$  y un ancho de  $5m$ . Este laboratorio está dedicado al desarrollo de proyectos del área agroindustrial enfocados a la producción vegetal protegida, cultivando diferentes tipos de plantas entre las cuales encontramos tomate, fresa, lechuga y chiles. En las siguientes secciones se describe la construcción, implementación y despliegue del sistema IoT propuesto.

##### A. Dispositivo IoT

La Fig. 2 muestra el dispositivo IoT desarrollado y construido para la fase de recopilación de datos. Este prototipo consiste de cinco componentes: una fuente de alimentación, un módulo de comunicación LPWAN de diseño propio (compatible con la placa Arduino UNO) y los sensores de temperatura, humedad relativa y  $CO_2$ .




Fig. 2. Prototipo del dispositivo IoT.

Para el monitoreo del ambiente dentro del invernadero se utilizaron los sensores PT1000 para la temperatura, DHT21

para la humedad relativa y el MH-Z19B para los niveles de  $\text{CO}_2$ . No obstante, el sensor DHT21 es capaz de medir la temperatura, se optó por utilizar el sensor PT1000 para asegurar una respuesta rápida y mayor precisión.

1) *Sensor de temperatura:* El sensor de precisión PT1000 es un tipo de detector de temperatura por variación de resistencia (RTD, por sus siglas en inglés), es decir, modifica su valor de resistencia en medida que varía la temperatura, para este trabajo se utiliza un modelo de tres hilos. Para calcular la temperatura a partir del valor de resistencia del sensor RTD se sigue el método matemático directo, este consiste en resolver la ecuación cuadrática derivada de la función de transferencia del sensor como se define en [38] y [39]. Para obtener una buena precisión del sensor se hace uso del módulo MAX31865 de Adafruit para leer los pequeños valores de resistencia entregados por el sensor, este módulo entrega el valor de resistencia a partir del protocolo SPI.

2) *Sensor de humedad relativa:* El sensor digital DHT21 incorpora un componente capacitivo para medir el porcentaje de humedad en el aire, además de un microcontrolador para la conversión de los valores analógicos a digitales. Su rango de medición para la humedad es de 0% a 100% con una precisión de  $\pm 3\%$  y una resolución de 0.1%. Este sensor cuenta con una cubierta que protege sus componentes internos para escenarios en exteriores, este puede ser alimentado por fuentes de 3.3V – 5V y se puede conectar a uno de los pines digitales del Arduino UNO.

3) *Sensor de  $\text{CO}_2$ :* Por último, el sensor analógico MH-Z19B basado en la tecnología de infrarrojo no disperso (NDIR, por sus siglas en inglés) se utiliza para medir la concentración de  $\text{CO}_2$ . Entre sus características principales ofrece un rango de medición que va desde los 0ppm hasta los 5000ppm, además de que no tiene dependencia de alguna otra variable ambiental como otros sensores. Este sensor entrega el valor de los niveles de  $\text{CO}_2$  a partir de un puerto de comunicación serial UART [40]. Para el correcto funcionamiento de este sensor, se debe realizar la calibración del punto cero, esto se refiere a definir el valor de voltaje al que corresponde una concentración de 400ppm. En este caso, la calibración del sensor se llevó a cabo en un lugar al aire libre, ya que en este ambiente se tiene una concentración cercana a los 400ppm.

### B. Estrategia de Monitoreo Espacial del Clima

La variabilidad del clima dentro de los invernaderos es un problema que se debe tener en consideración. En este aspecto, se propone hacer uso de una red de sensores bajo el enfoque de IoT. Para definir el número de sensores adecuado, así como su ubicación dentro del invernadero, se simplifica el problema al considerar la implementación de un conjunto de sensores con un radio de cobertura  $r$  en un espacio rectangular de dos dimensiones (2D) con un largo  $A$  y un ancho  $B$ . Para ello, se propone desarrollar una metodología basada en la teoría de empaquetamiento de círculos para maximizar el área de cobertura del invernadero minimizando el número de dispositivos IoT a utilizar. Esto se expresa como [41]:

$$P(r, S) = \frac{n\pi r^2}{S} \quad (1)$$

donde  $n$  es el número de círculos que no se traslapan y  $S$  el área del rectángulo.

Para mostrar la aplicación de este concepto se realizó un experimento que consistió en medir la variabilidad de la temperatura como función de la distancia. El propósito fue definir el radio de cobertura real de los dispositivos IoT. Como primer paso se tomaron muestras de la temperatura con un primer dispositivo IoT, colocado en el punto de referencia inicial  $p_{r1}$ , mientras que, un segundo dispositivo fue colocado en el punto  $p_{r2}$ , a una distancia  $d$  del primer dispositivo. Las mediciones se llevaron a cabo dentro del invernadero de la Facultad de Ingeniería, tomando muestras a las distancias de 1.8 m, 3.6 m, 5.4 m y 7.2 m con respecto del punto de referencia inicial (dispositivo 1). Para cuantificar la variabilidad de la temperatura se calculó la media absoluta ( $\mu$ ) y la desviación estándar ( $\sigma$ ) de la diferencia de temperatura entre el punto de referencia inicial y cada uno de los puntos alejados a la distancia  $d$ . La Fig. 3 muestra el comportamiento de estos parámetros, donde podemos observar como su valor crece conforme aumenta la distancia entre ellos, llegando a tener un valor  $\sigma$  cercano a los  $2^\circ\text{C}$  a una distancia de 7.2m. Basándonos en estos resultados, podemos definir una estrategia de monitoreo espacial a partir de (1), buscando la mejor relación entre la precisión, la cantidad de dispositivos a colocar dentro del invernadero (costo) y la cobertura.




Fig. 3. Desviación estándar y media de la variabilidad de la temperatura con respecto de la distancia dentro del invernadero.

El siguiente paso fue definir la estrategia de monitoreo espacial dentro del invernadero. Para esto, definimos  $A = 12\text{m}$  y  $B = 5\text{m}$ , las cuales son las dimensiones del invernadero utilizado para este caso de estudio. Con estos datos podemos calcular la eficiencia de empaquetamiento a partir de (1). Para definir el radio de cobertura  $r$  decidimos tomar dos escenarios, uno donde se define  $r = 1.8\text{m}$  y otro con  $r = 3.6\text{m}$ , esto con el objetivo de mostrar el efecto que tiene la elección de un radio de cobertura mayor, lo cual prioriza el costo (número de sensores) contra la precisión. La Tabla I muestra los resultados obtenidos para estos escenarios. Se puede observar que, para el primer escenario,  $r = 1.8\text{m}$ , se consigue un 100% de

cobertura utilizando 6 dispositivos IoT para  $\sigma = 0.92^\circ C$ . Para el segundo caso, donde  $r = 3.6m$ , se obtiene una cobertura del 100% con solo 2 dispositivos IoT, en este caso con  $\sigma = 1.2^\circ C$ .

TABLA I  
RESULTADOS OBTENIDOS PARA LOS ESCENARIOS CON  
 $r = 1.8m$  Y  $r = 3.6m$ .

No. de sensores	$r = 1.8m$	$r = 3.6m$
1	17%	67%
2	34%	100%
3	51%	
4	68%	
5	85%	
6	100%	

Lo siguiente es diseñar una propuesta para el despliegue de los dispositivos dentro del invernadero. En la Fig. 4a se presenta una propuesta para la distribución de los sensores para el caso con  $n = 6$ , mientras que en la Fig. 4b se presenta una propuesta para la distribución de los sensores con  $n = 2$ .

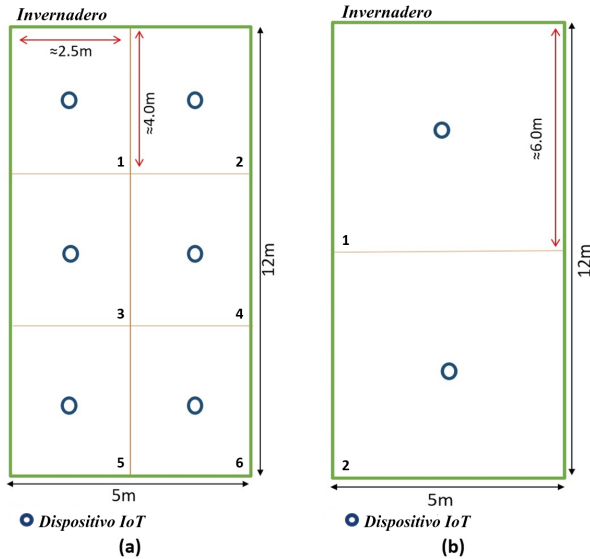


Fig. 4. Propuestas para la ubicación de los dispositivos IoT dentro del invernadero.

Con el objetivo de evaluar y comparar las dos estrategias de monitoreo propuestas, se construyeron un total de ocho dispositivos IoT para colocarlos dentro del invernadero. Estos dispositivos pueden medir valores de temperatura y humedad relativa, mientras que solo uno de ellos tiene la capacidad de percibir los niveles de  $CO_2$ , esto a través de los sensores anteriormente descritos en la Sección IV-A. La Fig. 5 muestra el despliegue de los dispositivos dentro del invernadero.

### C. Modelo Predictivo Climático

Para ejemplificar la implementación de un modelo predictivo basado en datos históricos como parte de la arquitectura IoT propuesta, se emplea una ANN de tres capas (entrada, capa oculta, salida), esto siguiendo el teorema de Kolmogorov el cual establece que cualquier función continua puede ser aproximada por una red con una sola capa oculta. Además, diversos trabajos han demostrado que las ANN ofrecen una



Fig. 5. Despliegue de la estrategia de monitoreo espacial del clima en un invernadero.

mejor relación rendimiento-complejidad [17], [18], [25]. Para este trabajo, se implementa este predictor para pronosticar el comportamiento de la temperatura, la humedad relativa y el  $CO_2$  dentro del invernadero. Por otro lado, cabe resaltar que este trabajo no tiene el objetivo de encontrar la mejor metodología para la predicción del clima, pero si la integración y el uso de un predictor como parte de la arquitectura IoT propuesta, así como la evaluación de su desempeño.

Para la predicción del ambiente se propone utilizar la metodología de series temporales, que consiste en utilizar un número específico de muestras pasadas tomadas en intervalos de tiempo uniformes, esto con el objetivo de predecir el comportamiento de la variable en el futuro. Para utilizar una ANN como predictor, primero se debe alterar el flujo de entrada de los datos, convirtiendo la serie temporal en un problema supervisado. Siguiendo esto, se propone como estrategia tomar como entrada las muestras de los días anteriores a una misma hora, y así predecir el valor de la variable en el siguiente día y a esa misma hora. Por ejemplo, para predecir la temperatura a las 10:00 hrs, se requiere como entrada los valores de temperatura recolectados durante  $n$  días anteriores a las 10:00 hrs. De esta manera, la predicción de una variable climática se puede expresar como:

$$\hat{x}[n] = \sum_{j=0}^M \omega_{j,1}^{(2)} \phi(a_j) \quad (2)$$

con

$$a_j = \begin{cases} 0 & \text{para } j = 0, \\ \sum_{i=0}^N w_{i,j}^{(1)} x[i] = \mathbf{x}^T \mathbf{w}_j^{(1)} & \text{Otros casos.} \end{cases} \quad (3)$$

donde  $\phi(a_j)$  es la salida de la  $j$ -ésima neurona con función de activación  $\tanh(a_j)$ ,  $X = [1, x[1], \dots, x[N]]^T$  el vector de entradas, y  $W = \{w_1^{(l)}, \dots, w_M^{(l)}\}$  donde  $w_j^{(l)} = (\omega_{1,j}^{(l)}, \dots, \omega_{N,j}^{(l)})$  con  $l = 1, 2$  el conjunto de pesos y sesgos en la red. Por simplicidad, se utiliza una notación que incluye los pesos ( $\omega_{i,j}$ ) y los sesgos ( $\omega_{0,j}$ ) en el vector  $w$ , por lo que se considera una entrada adicional  $x[0]$  que siempre tiene un valor de 1. La función de activación lineal,  $f(z) = z$ , determina la salida de la ANN. Por último, cabe mencionar

que la red es entrenada a partir del algoritmo back-propagation y el descenso del gradiente estocástico (SGD, por sus siglas en inglés), con una función de pérdida basada en el error cuadrático medio.

Para definir la estructura de la ANN se realizaron diversas pruebas variando algunos de los hiperparámetros como el número de entradas ( $N$ ) y el número de neuronas en la capa oculta ( $M$ ), esto tomando valores de  $N, M \in \{1, 2, 4, 6, 8, 10, 12\}$ . De esta manera, se entrenó y evaluó el desempeño de la red utilizando todas las combinaciones posibles entre los hiperparámetros  $N$  y  $M$  empleando un conjunto de datos sintéticos que simulan el comportamiento circadiano que tiene la temperatura, observando que el mejor rendimiento se obtiene con  $N = 8$  y  $M = 8$ .

Posteriormente se aplica un método de suavizado basado en las medias móviles del vector de muestras capturadas (temperatura, humedad o CO<sub>2</sub>) con el dispositivo IoT. Esto con el propósito de reducir el ruido generado por las estrategias de control del clima utilizadas dentro de los invernaderos. Para calcular la media móvil, simplemente se suma un conjunto de muestras y se divide por el número total de valores del conjunto, *i.e.*

$$x_s[k] = \sum_{k_s=-m}^m \frac{x[k - k_s]}{2m + 1} \quad (4)$$

donde  $2m + 1$  es el tamaño del conjunto de muestras. Cabe señalar que el proceso de suavizado es una etapa de post-procesamiento, por lo tanto se cuenta con las muestras anteriores y posteriores a cada uno de los instantes  $k = k_s$ . Para este trabajo se toma un valor de  $m = 5$ , además se asume que las primeras  $m$  muestras y las últimas  $m$  muestras del conjunto de datos no son promediadas.

#### D. Aplicación para el Usuario Final

El sistema de monitoreo IoT presentado en este trabajo, permite a los usuarios acceder a la información del estado de las condiciones ambientales dentro del invernadero a través de una aplicación web. Para crear esta aplicación, se sigue la metodología basada en el modelo vista-controlador (MVC, por sus siglas en inglés). Entre las principales características de esta aplicación encontramos un dashboard el cual contiene múltiples widgets para la gestión de los datos recolectados, la recopilación y visualización de datos en tiempo real de diferentes dispositivos, escalabilidad para administrar diversos dispositivos IoT y la posibilidad de crear múltiples cuentas de usuario.

### V. RESULTADOS Y DISCUSIÓN

La implementación del sistema IoT se realizó en el Laboratorio de producción vegetal protegida ubicado en la ciudad de San Luis Potosí, México. Este sistema estuvo en funcionamiento por un periodo aproximado de 3 meses. Durante este periodo, en el invernadero se llevaron a cabo las actividades manuales de mantenimiento y control como labores de riego, entre otras. Los datos del ambiente recolectados por los dispositivos IoT fueron enviados a un servidor en la nube para su almacenamiento y análisis. Además, se implementó una

aplicación web para hacer posible el monitoreo y visualización de los datos en tiempo real. La Fig. 6 muestra como ejemplo una consulta de los datos de la temperatura y humedad dentro del invernadero a través de la interfaz web en internet. Estos datos fueron recolectados cada 10 minutos, obteniendo un total de 144 muestras por día de cada una de las variables monitoreadas, esto durante un periodo de 87 días entre los meses de diciembre de 2021 y marzo de 2022, obteniendo un total de 12528 datos por cada variable monitoreada. Para demostrar el funcionamiento del sistema, se seleccionó la estrategia de monitoreo presentada en la Fig. 4a.




Fig. 6. Monitoreo de la temperatura y humedad visualizados en la interfaz web.

El primer paso para evaluar el desempeño del predictor es entrenar la ANN con el modelo ajustado a los datos correspondientes a las variables ambientales monitoreadas dentro del invernadero. Este proceso consiste en encontrar el conjunto óptimo de pesos y sesgos que minimicen la función de pérdida. Para esto, los datos fueron normalizados en el rango  $(-1, 1)$ , convirtiendo posteriormente la serie temporal correspondiente a cada variable climática en un problema supervisado, tal y como se explicó en la sección IV-C.

Con los datos acondicionados, se procede a separar 75% de los registros correspondiente a un total de 9396 datos para entrenar el modelo de la ANN y el restante 25%, correspondiente a 3132 muestras, para evaluar su capacidad de predicción. Después de desnormalizar los resultados de predicción se calcula la media del error absoluto (MAE), la raíz del error cuadrático medio (RMSE) y el error porcentual absoluto medio (MAPE), entre la predicción y el valor real entregado por el dispositivo IoT. Se sigue este mismo procedimiento utilizando las señales suavizadas obtenidas a partir de (4). La Tabla II muestran los resultados obtenidos para las diferentes variables ambientales monitoreadas.

TABLA II  
PREDICIONES DE LA TEMPERATURA, HUMEDAD RELATIVA Y NIVELES DE CO<sub>2</sub>.

	Temperatura		Humedad Relativa		CO <sub>2</sub>	
	Predicción	Medias móviles	Predicción	Medias móviles	Predicción	Medias móviles
MAE	2.04	1.78	13.64	12.51	37.9	31.84
RMSE	2.82	2.46	16.4	15.3	49.65	42.32
MAPE	11.9	8.4	39.8	24	6.6	4.6

Analizando los resultados presentados en la Tabla II, y tomando como ejemplo el caso de la temperatura, se puede

observar que la predicción alcanza un valor MAE de 2.04, mientras que se obtiene un valor RMSE de 2.82. En el caso del MAPE, este valor se incrementa a 11.9%, siendo este un indicador que mide el desempeño del predictor en términos porcentuales. También se puede observar como todos estos indicadores reducen su valor al implementar el suavizado por medias móviles. Este mismo comportamiento se muestra en los casos de las variables de humedad relativa y  $\text{CO}_2$ . Cabe señalar que los valores MAE y RMSE correspondientes al  $\text{CO}_2$  son mayores debido a los altos valores que puede llegar a tener esta variable, sin embargo, su MAPE es menor. De esta manera se obtiene un error porcentual para la temperatura de 8.4%, para el caso de la humedad se obtiene un error de hasta 24% y un error de solo 4.6% para el caso de  $\text{CO}_2$ . La Figura 7 presenta una muestra comparativa entre los valores de temperatura, humedad y de  $\text{CO}_2$  capturados con un dispositivo IoT y las predicciones realizadas por el modelo ANN. Los resultados anteriores muestran que el predictor propuesto es capaz de entregar un pronóstico del comportamiento de diferentes variables ambientales como la temperatura y el  $\text{CO}_2$  hasta de 24h. Por otro lado, la humedad relativa es la variable que menor precisión obtiene en su predicción, sin embargo, el resultado se considera aceptable tomando en cuenta la alta variación de esta variable a lo largo de un día.

Hasta ahora los resultados presentados corresponden solo a los registros obtenidos por uno de los dispositivos IoT, específicamente el marcado con el número 3, esto debido a que este cuenta con el sensor MH-Z19B para el monitoreo del  $\text{CO}_2$ . Sin embargo, es importante establecer si el modelo ANN obtenido con este dispositivo es válido para los datos registrados por cualquiera de los otros nodos dentro del invernadero. Para responder esto, y tomando como ejemplo el caso de la temperatura, se tomaron los pesos y sesgos obtenidos en el paso anterior (definidos a partir del dispositivo 3), llamado como modelo general, para predecir el comportamiento de la temperatura en el invernadero con los datos provenientes de otros nodos, en este caso los dispositivos 2 y 6. Para su comparación se definió un modelo ANN diferente e independiente para cada uno de los dispositivos. En la Tabla III se muestra la comparativa del error entre el modelo general y los modelos ANN independientes para cada dispositivo.

TABLA III  
EVALUACIÓN DE UN MODELO ANN GENERAL

	Modelo general			Modelo independiente		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE
Dispositivo 3	1.78	2.46	8.4			
Dispositivo 2	1.8	2.4	8.6	1.77	2.41	8.5
Dispositivo 6	1.86	2.6	9.3	1.68	2.25	8.0

Como se puede observar en la Tabla III, los resultados obtenidos muestran que el desempeño del predictor utilizando los datos del dispositivo 2 es muy similar usando ambos modelos, general e independiente, mientras que en el caso del dispositivo 6 este muestra un mejor desempeño mediante el modelo independiente. Con base en estos resultados podemos observar que es posible utilizar un mismo modelo ANN para la predicción de la temperatura en diferentes puntos dentro de un invernadero, esto empleando un mismo tipo de

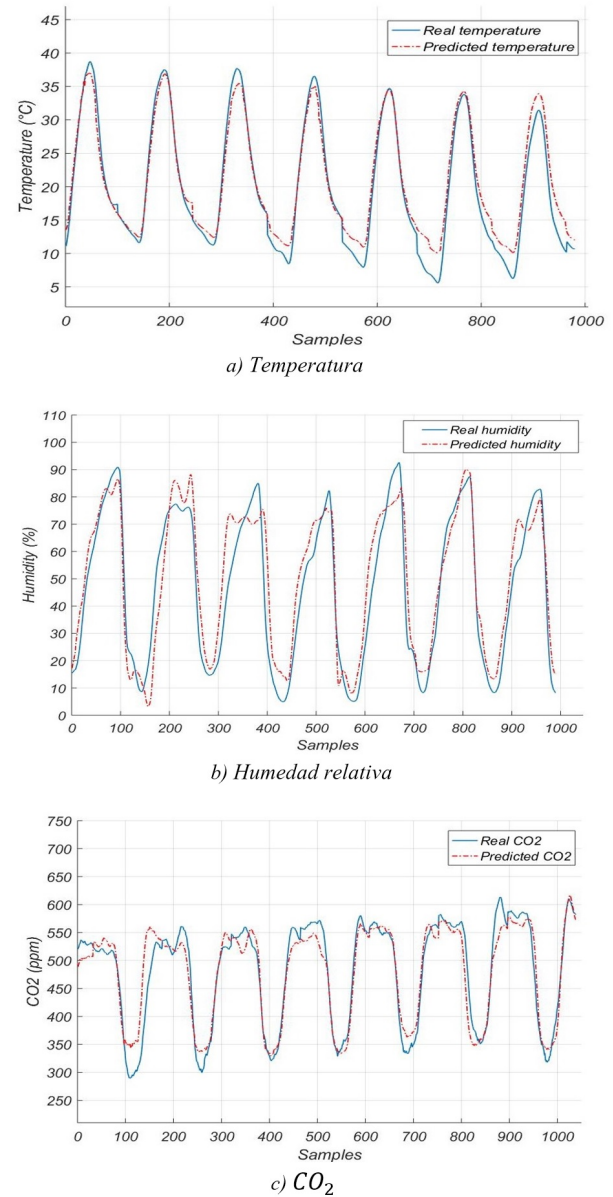


Fig. 7. Predicción del ambiente dentro de un invernadero.

sensor o dispositivo, como en este caso utilizando el sensor PT1000 en los dispositivos estudiados. Sin embargo, pueden existir puntos que se encuentren en áreas del invernadero con un comportamiento de la temperatura significativamente diferente por diversas razones, como en este caso ocurre con el dispositivo 6, el cual muestra obtener mejores resultados en la predicción al utilizar un modelo ANN independiente.

Finalmente, la Tabla IV muestra una comparativa de los resultados obtenidos en este trabajo con el estado del arte. Es importante resaltar que no existen muchas soluciones que propongan una metodología clara para definir el número de nodos a utilizar para cubrir la mayor área posible en un invernadero como la que se propone en este trabajo. Por otro lado, se muestra una comparativa del modelo de predicción climática tomando como ejemplo el caso de la temperatura. Sin embargo, no es posible realizar una comparativa justa al

momento de evaluar el desempeño de un predictor, esto debido a que diferentes estudios tienen un tiempo de predicción a futuro distinto, además de que algunos modelos predicen solo un valor promedio, máximo o mínimo de diferentes variables climáticas. Por último, es importante resaltar que no existen muchos trabajos que aborden estos dos temas en una misma solución.

TABLA IV

COMPARATIVA DEL SISTEMA PROPUESTO\* CONTRA TRABAJOS EXISTENTES EN EL ESTADO DEL ARTE ACTUAL.

	*	[25]	[18]	[31]	[34]	[35]
Capacidad de predicción	Si	Si	Si	No	No	No
Tiempo de predicción	24H	10Min	1H	-	-	-
Desempeño (MAPE)	8.4%	1.04%	4.91%	-	-	-
Desempeño (RMSE)	2.4°C	0.402°C	1.5°C	-	-	-
Monitoreo espacial	Si	No	No	Si	Si	Si
Número de nodos	2, 6	-	-	5	9	56
Escalabilidad	Si	-	-	No	No	No

## VI. CONCLUSIONES

En este trabajo se presentó una metodología para la implementación de un sistema IoT, eficiente y de bajo costo, con aplicación al monitoreo y predicción del clima en invernaderos inteligentes. El sistema fue probado y validado dentro de un invernadero en México durante tres meses.

El sistema propuesto aborda el problema de la falta de homogeneidad en el clima mediante una solución de monitoreo espacial basada en la teoría de densidad de empaquetamiento. Esta solución ofrece un compromiso entre la precisión y el costo, maximizando el área de cobertura y minimizando el número de dispositivos IoT utilizados. En particular, se mostró que con dos dispositivos IoT se logró una cobertura del 100% del invernadero estudiado en la Sección IV, produciendo un error en la estimación de la temperatura de 1.2°C, mientras que con seis dispositivos IoT el error fue de 0.92°C.

Cabe resaltar que las soluciones en el estado del arte no cuentan con una metodología para definir y desplegar el número de dispositivos para el monitoreo del clima en invernaderos, por lo que la propuesta que aquí se presenta se considera una contribución al problema. Lograr la igualdad climática a bajo costo es importante porque garantiza un crecimiento uniforme del cultivo y consecuentemente su producción.

Con respecto a la predicción del ambiente dentro del invernadero, los resultados obtenidos muestran dos puntos importantes. El primero es que, en comparación de otros modelos presentados en el estado del arte, este modelo es capaz de predecir con 24h de anticipación el comportamiento de diversas variables ambientales utilizando tan solo 8 muestras anteriores de la misma variable. Esta información ofrecerá al agricultor la oportunidad de planificar de mejor manera las diferentes actividades de mantenimiento y control dentro del invernadero a lo largo del día e incluso a tomar acciones preventivas contra plagas y enfermedades. Como segundo punto relevante, se comprobó que no es necesario definir un modelo de predicción diferente para cada uno de los dispositivos IoT que conforman

la red de sensores del invernadero, si no que se puede emplear un mismo modelo ANN.

Como trabajo futuro se vislumbra realizar un estudio a profundidad del comportamiento del modelo predictivo, propuesto en este trabajo, considerando su desempeño como función de las estaciones del año. Esto con el objetivo de conocer su comportamiento y precisión bajo estas condiciones. Por otro lado, se plantea realizar un estudio acerca de la eficiencia que tiene la metodología presentada en este trabajo para definir una estrategia de monitoreo espacial del clima en invernaderos con áreas no rectangulares o irregulares.

## REFERENCES

- [1] N. Genhua and J. Masabni. "Plant Production in Controlled Environments," *Horticulturae*, vol.4, no. 4:28, 2018. <https://doi.org/10.3390/horticulturae4040028>
- [2] X. Shi et al., "State-of-the-Art Internet of Things in Protected Agriculture," *Sensors*, vol. 19, no. 8, p. 1833, Apr. 2019, doi:10.3390/s19081833.
- [3] S. M.-e. Rezvani, H. Z. Abyaneh, R. R. Shamshiri, S. K. Balasundram, V. Dworak, M. Goodarzi, M. Sultan and B. Mahns. "IoT-Based Sensor Data Fusion for Determining Optimality Degrees of Microclimate Parameters in Commercial Greenhouse Production of Tomato" *Sensors* 20, no. 22: 6474. 2020. <https://doi.org/10.3390/s20226474>
- [4] R. K. Kodali, S. C. Rajanarayanan and L. Boppana, "IoT based Weather Monitoring and Notification System for Greenhouses," in 11th International Conference on Advanced Computing (ICoAC), 2019. doi:10.1109/icoac48765.2019.24686
- [5] M. C. Sánchez-Guerrero, P. Lorenzo, E. Medrano, N. Castilla, T. Soriano, A. Baille, "Effect of variable CO2 enrichment on greenhouse production in mild winter climates", *Agricultural and Forest Meteorology*, (132), pp. 244-252, 2005.
- [6] S. Santiteerakul, A. Sopadang, K. Y. Tippayawong, and K. Tamvimol, "The Role of Smart Technology in Sustainable Agriculture: A Case Study of Wangree Plant Factory", *Sustainability*, vol. 12, no. 11: 4640, 2020. <https://doi.org/10.3390/su12114640>.
- [7] M. Ayaz, M. Ammad-Uddin, Z. Sharif, A. Mansour and E.M. Aggoune, "Internet-of-Things (IoT)-Based Smart Agriculture: Toward Making the Fields Talk", in *IEEE Access*, vol. 7, pp. 129551-129583, 2019.
- [8] Y. Liu, X. Ma, L. Shu, G. P. Hancke and A. M. Abu-Mahfouz, "From Industry 4.0 to Agriculture 4.0: Current Status, Enabling Technologies, and Research Challenges", in *IEEE Transactions on Industrial Informatics*, vol. 17, no. 6, pp. 4322-4334, June 2021, doi: 10.1109/TII.2020.3003910.
- [9] M. S. Farooq, S. Riaz, A. Abid, K. Abid and M. A. Naeem, "A Survey on the Role of IoT in Agriculture for the Implementation of Smart Farming", in *IEEE Access*, vol. 7, pp. 156237- 156271, 2019, doi: 10.1109/ACCESS.2019.2949703.
- [10] N.N. Misra, Y. Dixit, A. Al-Mallahi, M.S. Bhullar, R. Upadhyay, A. Martynenko, "IoT, Big data and artificial intelligence in agriculture and food industry," *IEEE Internet Things J.* 2020. <http://dx.doi.org/10.1109/JIOT.2020.2998584>.
- [11] E. A. Abioye, O. Hensel, T. J. Esau, Olakunle Elijah, Mohamad S.Z. Abidin, A. S. Ayobami, O. Yerima, and A. Nasirahmadi. 2022. "Precision Irrigation Management Using Machine Learning and Digital Farming Solutions" *AgriEngineering*, vol. 4, no. 1: 70-103. <https://doi.org/10.3390/agriengineering4010006>
- [12] T. Pisanu, S. Garau, P. Ortu, L. Schirru, and C. Macciò, "Prototype of a Low-Cost Electronic Platform for Real Time Greenhouse Environment Monitoring: An Agriculture 4.0 Perspective," *Electronics* vol. 9, no. 5: 726, 2020. <https://doi.org/10.3390/electronics9050726>
- [13] G. E. Vazquez-Becerra, "In-Field Electronic Based System and Methodology for Precision Agriculture and Yield Prediction in Seasonal Maize Field", *IEEE LAT AM T*, vol. 17, no. 10, pp. 1598-1606, Dec. 2019.
- [14] A. F. Subahi and K. E. Bouazza, "An Intelligent IoT-Based System Design for Controlling and Monitoring Greenhouse Temperature," in *IEEE Access*, vol. 8, pp. 125488-125500, 2020, doi: 10.1109/ACCESS.2020.3007955.
- [15] P. K. Tripathy, A. K. Tripathy, A. Agarwal, and S. P. Mohanty, "MyGreen: An IoTEnabled Smart Greenhouse for Sustainable Agriculture," *IEEE Consumer Electronics Magazine*, 10(4), 57-62, 2021. doi:10.1109/mce.2021.3055930
- [16] G. W. Archbold, "pH Measurement IoT System for Precision Agriculture Applications", *IEEE LAT AM T*, vol. 17, no. 5, pp. 823-832, Nov. 2019.

- [17] I. Ullah, M. Fayaz, N. Naveed and D. Kim, "ANN Based Learning to Kalman Filter Algorithm for Indoor Environment Prediction in Smart Greenhouse," in *IEEE Access*, vol. 8, pp. 159371-159388, 2020, doi: 10.1109/ACCESS.2020.3016277.
- [18] G. Codeluppi, A. Cilfone, L. Davoli, and G. Ferrari, "AI at the Edge: A Smart Gateway for Greenhouse Air Temperature Forecasting," 2020 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor), 2020. doi:10.1109/metroagrifor50201.2020
- [19] G. Storey, M. Qinggang, and L. Baihua, "Leaf Disease Segmentation and Detection in Apple Orchards for Precise Smart Spraying in Sustainable Agriculture," *Sustainability* vol. 14, no. 3: 1458, 2022 <https://doi.org/10.3390/su14031458>
- [20] L. Gong, M. Yu, S. Jiang, V. Cutsuridis, and S. Pearson, "Deep Learning Based Prediction on Greenhouse Crop Yield Combined TCN and RNN," *Sensors* vol. 21, no. 13: 4537, 2021. <https://doi.org/10.3390/s21134537>
- [21] T. Konstantinos, A. Al-Zoubi, N. Christofides, C. Zannettis, M. Chrysostomou, S. Panteli, and A. Antoniou, "Reliable IoT-Based Monitoring and Control of Hydroponic Systems," *Technologies* vol. 10, no. 1: 26, 2022. <https://doi.org/10.3390/technologies10010026>
- [22] J. Yang, M. Liu, J. Lu, Y. Miao, M. A. Hossain, and M. F. Alhamid, "Botanical Internet of Things: Toward Smart Indoor Farming by Connecting People, Plant, Data and Clouds," *Mobile Networks and Applications*, 23(2), 188–202, 2017. doi:10.1007/s11036-017-0930-x
- [23] M. C. Al Fajar and O. N. Samijayani, "Real time Greenhouse Environment Monitoring Based on LoRaWAN Protocol using Grafana," 2021 International Symposium on Electronics and Smart Devices (IESD), 2021, pp. 1-5, doi: 10.1109/IESD53023.2021.9501628.
- [24] R. K. Singh, M. Aernouts, M. De Meyer, M. Weyn, and R. Berkvens, "Leveraging LoRaWAN Technology for Precision Agriculture in Greenhouses," *Sensors* vol. 20, no. 7: 1827, 2020. <https://doi.org/10.3390/s20071827>
- [25] G. Codeluppi, L. Davoli, and G. Ferrari, "Forecasting Air Temperature on Edge Devices with Embedded AI," *Sensors* 21, no. 12: 3973, 2021. <https://doi.org/10.3390/s21123973>
- [26] A. Ali, and H. S. Hassanein, "Time-Series Prediction for Sensing in Smart Greenhouses," *GLOBECOM 2020 - 2020 IEEE Global Communications Conference*, 2020. doi:10.1109/globecom42002.2020.93
- [27] X. Chen, X. Wang, and H. Shen, "Design of Greenhouse Environment Monitoring System based on NB-IoT And Edge Computing," 2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), 2021. doi:10.1109/iaeac50856.2021.93906
- [28] A. Mellit, M. Benganem, O. Herrak, A. Messalaoui, "Design of a Novel Remote Monitoring System for Smart Greenhouses Using the Internet of Things and Deep Convolutional Neural Networks," *Energies* 2021, 14, 5045. <https://doi.org/10.3390/en14165045>
- [29] A. Goap, D. Sharma, A.K. Shukla, C. Rama Krishna, "An IoT based smart irrigation management system using Machine learning and open-source technologies," *Computers and Electronics in Agriculture*, Volume 155, 2018, Pages 41-49, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2018.09.040>.
- [30] Ritesh K. Singh, H. Rahmani Mohammad, M. Weyn, and R. Berkvens, "Joint Communication and Sensing: A Proof of Concept and Datasets for Greenhouse Monitoring Using LoRaWAN," *Sensors* 22, no. 4: 1326, 2022 <https://doi.org/10.3390/s22041326>
- [31] Konstantinos P. Ferentinos, N. Katsoulas, A. Tzounis, T. Bartzanas, C. Kittas, "Wireless sensor networks for greenhouse climate and plant condition assessment," *Biosystems Engineering*, Vol. 153, 2017, Pages 70-81, ISSN 1537-5110, <https://doi.org/10.1016/j.biosystemseng.2016.11.005>.
- [32] B. Erfianto, A. Rakhmatsyah, and E. Ariyanto, (2020). "Micro-Climature Control for Hydroponics in Greenhouses," 2020 8th International Conference on Information and Communication Technology (ICOICT). doi:10.1109/icoict49345.2020.9166
- [33] H. Liu, Z. Meng and S. Cui, "A Wireless Sensor Network Prototype for Environmental Monitoring in Greenhouses," 2007 International Conference on Wireless Communications, Networking and Mobile Computing, Shanghai, 2007, pp. 2344-2347, doi: 10.1109/WICOM.2007.584.
- [34] S. Lee, I. Lee, U. Yeo, R. Kim, and J. Kim, "Optimal sensor placement for monitoring and controlling greenhouse internal environments," *Biosystems Engineering*, 188, 190–206, 2019. doi:10.1016/j.biosystemseng.2019.
- [35] D. D. Uyeh et al., "A Reinforcement Learning Approach for Optimal Placement of Sensors in Protected Cultivation Systems," in *IEEE Access*, vol. 9, pp. 100781-100800, 2021, doi:10.1109/ACCESS.2021.3096828.
- [36] B. Mazon-Olivo and A. Pan, "Internet of Things: State-of-the-art, Computing Paradigms and Reference Architectures", *IEEE LAT AM T*, vol. 20, no. 1, pp. 49–63, May 2021.
- [37] R.K. Singh, R. Berkvens and M. Weyn, "Agrifusion: An architecture for IoT and emerging technologies based on a precision agriculture survey," *IEEE Access* 9 (2021) 136253–136283, <http://dx.doi.org/10.1109/ACCESS.2021.3116814>.
- [38] C. A. Hernández-Morales, J.M. Luna-Rivera, Rafael Perez-Jimenez, "Design and deployment of a practical IoT-based monitoring system for protected cultivations," *Computer Communications*, Volume 186, 2022, Pages 51-64, ISSN 0140-3664, doi.org/10.1016/j.comcom.2022.01.009.
- [39] www.analog.com. 'RTD Interfacing and Linearization Using an ADuC8xxMicroConverter', 2014. Available online: [https://www.analog.com/media/en/technical-documentation/application-notes/AN709\\_0.pdf](https://www.analog.com/media/en/technical-documentation/application-notes/AN709_0.pdf). [Accessed: 20-Feb-2022].
- [40] G. Coulby, Adrian K. Clear, O. Jones, A. Godfrey, "Low-cost multimodal environmental monitoring based on the Internet of Things, Building and Environment", Volume 203, 2021, 108014, ISSN 0360-1323, <https://doi.org/10.1016/j.buildenv.2021.108014>.
- [41] P. G. Szabo, M. C. Markot, T. Csendes, E. Specht, L. G. Casado, and I. Garcia, "New approaches to circle packing in a square: with program codes," in *Optimization and Its Applications*, vol. 6, Springer, New York, NY, USA, 2007.



**Carlos A. Hernández-Morales** received the Bachelor's degree in telematics engineering from the Polytechnic University of San Luis Potosi, Mexico in 2016 and the master's degree in electronic engineering from the Autonomous University of San Luis Potosi, Mexico in 2019. He is currently a Ph.D. student at the Autonomous University of San Luis Potosi. His research interests include internet of things, embedded systems, machine learning, smart agriculture, wireless sensor networks and analytics.



**Jose Martin Luna-Rivera** received the B.S. and M.Eng. in electronics engineering from the Autonomous University of San Luis Potosi, Mexico, in 1997 and 1998, respectively. He received the Ph.D. degree in electrical engineering from the University of Edinburgh, UK, in 2003. He is currently a full-time professor at the Faculty of Sciences of the Autonomous University of San Luis Potosi, Mexico. In 2014, he received the "University Award for Technological and Scientific Research" as a Young Researcher from the Autonomous University of San

Luis Potosi. His research interests focus on applying signal processing for wireless communication systems, including developing techniques and algorithms for array signal detection, efficient modulation schemes, transmit/receive diversity schemes, channel modeling, signal precoding, interference cancellation, and power control techniques. Applications of this research work include Visible Light Communications, Vehicular Communications, Internet of Things, and Mobile Communications, which has resulted in over 100 journals and refereed conference publications.



**Federico Villarreal-Guerrero**, Professor and Researcher at the School of Animal Sciences and Ecology, University of Chihuahua, Mexico. B.S. Agricultural Engineer, graduated in 2011, University of Chapingo, Mexico; M.Sc. Horticultural Sciences, graduated in 2005, University of Chihuahua, Mexico; Ph.D. Agricultural and Biosystems Engineering, graduated in 2011, University of Arizona, USA; Worked as a Professor and Researcher at the University of San Luis Potosí during 2011-2014 and at the University of Chihuahua from 2014 to date.

Current and previous research interests focus on physiological plant responses to the environment under both, natural and controlled conditions. That includes responses to abiotic stress and climate change.



**Pablo Delgado-Sánchez**, Professor Researcher Doctor in Applied Sciences (2011), Instituto Potosino de Investigación Científica y Tecnológica-IPICYT, A.C. Master in sciences in Molecular Biology (2007), Instituto Potosino de Investigación Científica y Tecnológica-IPICYT, A.C. Agricultural Chemist (2004), Universidad Veracruzana. Professor Researcher and Coordinator of the Doctorado en Ciencias Agropecuarias, Facultad de Agronomía y Veterinaria, Universidad Autónoma de San Luis Potosí. My research is focused on the study of physiological and molecular mechanisms of plants exposed to abiotic stress conditions (drought, salinity, and solar radiation). Member of the Sociedad Mexicana de Bioquímica, A.C., Sociedad Mexicana de Biotecnología y Bioingeniería, and the Sistema Nacional de Investigadores Nivel I. AgroBIO-México Award 2012 for Best D.Sc. Thesis of Research in Plant Biotechnology.



**Zoe Arturo Guadiana-Alvarado** received the bachelor's degree in agricultural engineering, the master's degree in technology and water management and the Ph.D. degree in environmental science from the Autonomous University of San Luis Potosí, Mexico in 2007, 2014 and 2020 respectively. He is currently a research professor at engineering faculty of the Autonomous University of San Luis Potosí, Mexico since 2013. His research interests includes protected agriculture (greenhouses), environmental sciences and sustainable development.