

Diseño de un gemelo digital basado en la integración IoT-IA: Caso de uso en el proyecto CANNADIG

Inicial. Apellido¹, Inicial. Apellido² y Inicial. Apellido¹ (Times New Roman 12)

¹ Dirección de contacto del autor principal (TNR 10), incluyendo Institución, dirección postal, ciudad, país (si no es España) y e-mail: email@email.com

² Direcciones de contacto no coincidentes con el autor principal. (Times New Roman 10)

Resumen

El trabajo refleja el diseño de un modelo para el desarrollo de gemelos digitales empleados en la optimización de recursos y procesos en invernaderos automatizados, utilizados en el cultivo de cáñamo industrial, en el contexto del proyecto de investigación CANNADIG. Se propone un modelo basado en el uso de tecnologías de captura de datos IoT y el desarrollo de un agente que utiliza en el algoritmo Q-Learning de aprendizaje por refuerzo (RL). La integración de ambas tecnologías en un entorno controlado como es el invernadero proporciona las herramientas necesarias para el desarrollo de gemelos digitales que reproducen los estados de las variables analizadas para optimizar recursos. El modelo se ha testado en un invernadero acristalado con el objetivo de optimizar el consumo energético a partir de seleccionar la temperatura de referencia (setpoint) introducida al sistema de climatización. Mediante el uso del gemelo digital el técnico puede valorar, con antelación, la selección más adecuada para cada jornada.

Palabras clave: gemelos digitales, IoT, Inteligencia Artificial, aprendizaje por refuerzo en invernadero

Centered Title, in bold, (14-point size, Times New Roman font).

Abstract

The work reflects the design of a model for the development of digital twins used in the optimization of resources and processes in automated greenhouses, employed in the cultivation of industrial hemp, in the context of the CANNADIG research project. A model based on the use of IoT data capture technologies and the development of an agent that uses the Q-Learning algorithm of reinforcement learning (RL) is proposed. The integration of both technologies in a controlled environment such as the greenhouse provides the necessary tools for the development of digital twins that reproduce the states of the analyzed variables to optimize resources. The model has been tested with the goal of optimizing energy consumption by selecting the reference temperature (setpoint) introduced into the air conditioning system. By using the digital twin, the technician can assess in advance the most suitable selection for each day.

Keywords: digital twins, IoT, Artificial Intelligence, reinforcement learning in greenhouse

Introducción y/o Justificación

Los gemelos digitales son réplicas virtuales de procesos, servicios o sistemas físicos que permiten la simulación, el monitoreo y el análisis de datos en un entorno virtual que refleja su comportamiento físico (Fatima, 2022). El diseño de gemelos digitales que utilizan tecnologías habilitadoras digitales como el Internet de las Cosas (IoT) y paradigmas de Inteligencia Artificial (IA) aportan nuevas herramientas para su desarrollo. La integración entre modelos físicos, IoT y paradigmas IA facilita la creación de representaciones virtuales de sistemas físicos, permitiendo una simulación, análisis y optimización en tiempo real que puede adaptarse mejor a todo tipo de escenarios con características específicas. El paradigma de Inteligencia Artificial que ofrece mayor amplitud y adaptación a condiciones de instalaciones específicas es el del aprendizaje por refuerzo (RL). En el trabajo de Nakatani et al., 2022 se aporta una visión interesante de cómo se puede mejorar una tarea específica de aprendizaje automático mediante la aplicación de técnicas de aprendizaje por refuerzo. En el estudio de Abualigah et al. 2022, se resalta la capacidad del aprendizaje por refuerzo para mejorar el control de sistemas complejos y adaptativos. El aprendizaje por refuerzo para el control de invernaderos autónomos, aprende políticas de plantación más efectivas y robustas que los métodos existentes (Zhang, 2021).

Material y Métodos

Este trabajo representa la propuesta de desarrollo de gemelos digitales del proyecto de investigación CANNADIG, implementado en un invernadero automatizado para un cultivo de cáñamo industrial. Para obtener los datos de las condiciones ambientales, y de la planta se han instalado un conjunto de sensores que se comunican con protocolos de comunicación IoT (MQTT, WiFi). Los datos se obtienen en tiempo real y se almacenan en formato csv para su posterior análisis. Sobre los datos almacenados se analiza el comportamiento de la temperatura del invernadero y se ajusta un modelo térmico que depende de la temperatura en el exterior y de la energía suministrada por las máquinas de climatización, que se activan de forma programada atendiendo a las consignas o setpoints (T_{max} y T_{min}) introducidas por el técnico del invernadero.

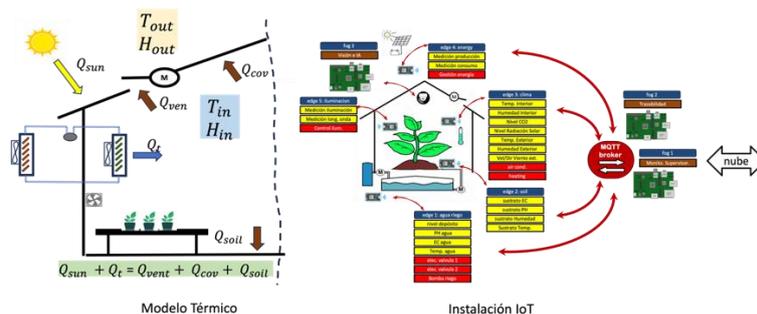


Figura 1. Modelo térmico y despliegue IoT

En la figura 1 se muestra el modelo térmico utilizado en el desarrollo numérico del gemelo digital y la descripción de la instalación IoT desplegada en el invernadero.

Con los datos capturados y el modelo térmico se obtienen los datos de entrada al algoritmo que va a desarrollar la funcionalidad de un gemelo digital para el análisis del consumo energético y gestión de la temperatura en el interior del invernadero. El

algoritmo está basado en el desarrollo de un “agente inteligente” que aplica el mecanismo definido en el paradigma de “aprendizaje por refuerzo” mediante Q-Learning. El agente aprende a partir de la experiencia, ajustando sus predicciones de recompensa para cada acción en cada estado del entorno a través de la exploración y la explotación. Este aprendizaje se representa a menudo en una tabla de Q-valores, conocida como tabla Q-learning, donde cada entrada indica el valor Q asociado a un par estado-acción, es decir, la recompensa esperada al tomar una acción en un estado específico. En el contexto del trabajo mencionado, el algoritmo Q-learning se aplica para optimizar decisiones a lo largo de las 24 horas del día. Cada hora del día se considera un estado dentro del entorno, lo que resulta en un total de 24 estados distintos. Para cada uno de estos estados (horas), el algoritmo evalúa un conjunto de acciones disponibles. Cada acción tiene asociado un conjunto de valores de recompensa, representados en la tabla Q-learning, que indica la efectividad de esa acción en el estado dado en términos de la recompensa esperada. En esta instalación, el sistema de climatización se controla a partir de la selección del “setpoint” de las condiciones climáticas deseadas. El técnico especialista recibe la necesidad de las condiciones climáticas (temperatura-humedad) del cultivo a lo largo de la jornada. Se registran también datos externos climáticos que forman parte del dataset. Finalmente, se incorporan los valores del setpoint para el control de la temperatura seleccionada, que será la referencia a la máquina de clima. Al mismo tiempo, con un sensor de consumo, se obtiene y registra el consumo eléctrico de la instalación. Todo ello de forma horaria. Cada hora el técnico puede programar un nuevo “setpoint” en función de su experiencia. El algoritmo reproduce el comportamiento de control del técnico simulando el comportamiento ambiental, ajustando el valor elegido para reducir el consumo energético. El sistema simulado permite analizar estrategias de control utilizando parámetros de entrada al sistema como la temperatura de consigna y las acciones correctoras que sobre ella el sistema puede realizar de forma automática para optimizar el consumo energético. La función Q se maximiza para lograr el mínimo número de conexiones de la bomba de calor del invernadero.

Resultados y Discusión

Los resultados obtenidos al aplicar el algoritmo es el ajuste en una tabla de valores Q obtenidos cada día, se muestra un ejemplo en la figura 2. En la tabla se señala que a las 5h la mejor acción posible es la que marca un “setpoint” disminuido en 3 o 4 grados, para el registro de la temperatura máxima a la cual la bomba de calor debe actuar. La actualización de la temperatura permite disminuir el número de conexiones de la bomba de calor llegando a ahorros del 30% diarios en función de la evolución de la temperatura en el exterior. La tabla Q muestra las mejores acciones de control posibles a aplicar con las condiciones externas capturadas en la predicción meteorológicas.

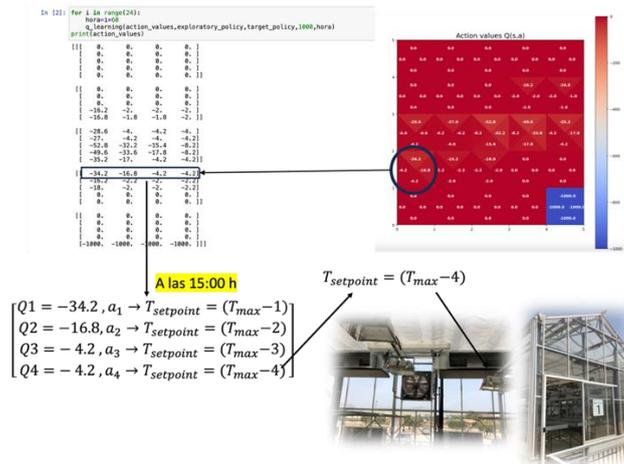


Figura 2. Resultados en la aplicación del algoritmo y escenario de aplicación

Conclusiones

Uno de los objetivos del trabajo es obtener el diseño para modelar gemelos digitales que reproduzcan el comportamiento físico a partir de una reproducción virtual. El diseño del gemelo digital propuesto se muestra en la figura 5. Se trata de un modelo para construir otros gemelos digitales que puedan modelar otras condiciones hasta llegar al modelado del crecimiento de la planta ante acciones como el riego, iluminación y condiciones ambientales. De los resultados obtenidos se concluye la validación del modelo de integración de tecnología IoT y el paradigma de aprendizaje por refuerzo (RL) que parte de modelos numéricos del comportamiento térmico específico del invernadero y de la predicción de la evolución en la temperatura exterior para obtener de ese modo la temperatura de consigna que minimiza el consumo energético manteniendo los valores de temperatura en el interior programados.

Agradecimientos

Este espacio se reserva para incluir las fuentes de financiación de los trabajos, el nombre del proyecto o datos similares. No incluir agradecimientos a amigos, familiares o personal del Centro o laboratorio.

Bibliografía Environmental Sciences Proceedings

Abualigah, L., Diabat, A., Mirjalili, S., Elaziz, M. A., & Gandomi, A. H. 2022. Deep Reinforcement Learning for Integrated Non-Linear Control of Autonomous UAVs. Processes, 10(7), 1307.

Fatima K, Hussain S, Khan SA, Khan MA, Saleem SR, Kanwal S. 2022. Digital Twin Greenhouse Technologies for Commercial Farmers. 23(1):33. <https://doi.org/10.3390/envirosci2022023033>

Nakatani, Y., Kajiwara, T., & Ninomiya, T. 2022. Comparing BERT-based Reward Functions for Deep Reinforcement Learning in Machine Translation. In Proceedings of the 9th Workshop on Asian Translation (pp. 37–43). International Conference on Computational Linguistics.

Zhang, W., Cao, X., Yao, Y., An, Z., Luo, D., & Xiao, X. 2021. Robust Model-based Reinforcement Learning for Autonomous Greenhouse Control. ArXiv, abs/2108.11645.