



## Predicting greenhouse microclimatic parameters using a deep learning algorithm

Hajir Ein Ghaderi<sup>1</sup> | Reza Alimardani<sup>2</sup> | Seyed Saeid Mohtasebi<sup>3</sup> | Mohammad Hosseinpour-Zarnaq<sup>4</sup>

1. Department of Agricultural Machinery Engineering, Faculty of Agriculture, University of Tehran, Karaj, Iran. E-mail: [hajir.ghaderi1991@gmail.com](mailto:hajir.ghaderi1991@gmail.com)
2. Corresponding Author, Department of Agricultural Machinery Engineering, Faculty of Agriculture, University of Tehran, Tehran, Iran. E-mail: [rmardani@ut.ac.ir](mailto:rmardani@ut.ac.ir)
3. Department of Agricultural Machinery Engineering, Faculty of Agriculture, University of Tehran, Karaj, Iran. E-mail: [mohtaseb@ut.ac.ir](mailto:mohtaseb@ut.ac.ir)
4. Department of Agricultural Machinery Engineering, Faculty of Agriculture, University of Tehran, Karaj, Iran. E-mail: [huseinpour@ut.ac.ir](mailto:huseinpour@ut.ac.ir)

Article Info	ABSTRACT
<p><b>Article type:</b> Research Article</p> <p><b>Article history:</b></p> <p><b>Received:</b> Jan. 5, 2025</p> <p><b>Revised:</b> March. 22, 2025</p> <p><b>Accepted:</b> Apr. 8, 2025</p> <p><b>Published online:</b> Winter 2025</p> <p><b>Keywords:</b> <i>Smart greenhouses, Artificial intelligence, Simulation models.</i></p>	<p>Providing proper conditions for plant growth in the greenhouse requires precise management of resources concerning operating costs. Consequently, an automatic and efficient greenhouse weather control system is needed for accurate management and cost reduction. Traditionally, dynamic models have been valuable tools for controlling the greenhouse climate. In this research, the design of a system for predicting the environmental conditions of the greenhouse was studied using deep learning. The developed method was implemented to ensure precise conditions for the production of tomato crops in a glass greenhouse. The deep learning-based model successfully predicted the greenhouse temperature, relative humidity, and carbon dioxide concentration using inputs such as wind speed, the virtual sky temperature, cumulative outside global radiation, outside photosynthetically active radiation, outside temperature, outside relative humidity, and outside carbon dioxide concentration, with coefficients of determination of 0.81, 0.61, and 0.85, respectively. The performance of the deep neural network was significant due to the utilization of precise data controlled by expert operators. Compared to dynamic modelling, the advantages of the suggested framework include high stability, adaptability for use without the need for a previous model, the ability to make unlimited decisions, and low complexity in real-time training. Therefore, smart artificial intelligence methods can lead to finding the best solution for optimal greenhouse control, enhancing performance, and reducing costs while addressing other limitations.</p>
<p>Cite this article: Ein Ghaderi, Alimardani, A., H., Mohtasebi, S. S., &amp; Hosseinpour-Zarnaq, M. (2025). Predicting greenhouse microclimatic parameters using a deep learning algorithm, <i>Iranian Journal of Biosystem Engineering</i>, 55 (4), 63-79. <a href="https://doi.org/10.22059/ijbse.2025.388236.665578">https://doi.org/10.22059/ijbse.2025.388236.665578</a></p> <p>© The Author(s). Publisher: The University of Tehran Press.</p> <p>DOI: <a href="https://doi.org/10.22059/ijbse.2025.388236.665578">https://doi.org/10.22059/ijbse.2025.388236.665578</a></p>	



## EXTENDED ABSTRACT

### Introduction

Population growth, increased demand for food, and climate change have placed significant pressure on water resources. Agricultural production accounts for 85% of global water consumption. One effective solution to this challenge, which has garnered substantial attention over the past few decades, is greenhouse cultivation. Various models, including dynamic models, black-box models, and machine learning models, have been developed to predict and control greenhouse environmental conditions and support plant growth. Dynamic models, based on mass and energy equations, govern the internal environment of greenhouses. Recent advancements in artificial intelligence have enabled smart control of greenhouse microclimates, focusing on maximizing production while reducing costs. Deep learning-based models represent cutting-edge methods capable of analyzing large volumes of data with complex patterns. This research aims to predict environmental conditions inside greenhouses using artificial intelligence algorithms and to compare these predictions with traditional dynamic models. The outputs will be assessed against actual conditions, environmental changes, and disturbances.

### Materials and Methods

The deep neural network designed to simulate the environmental conditions inside the greenhouse incorporates various inputs, including wind speed, virtual sky temperature, cumulative outside global radiation, outside photosynthetically active radiation, outside temperature, outside relative humidity, and outside carbon dioxide concentration. The outputs of the network are temperature, humidity, and carbon dioxide concentration within the greenhouse. Python serves as the foundational programming language for developing deep learning models, enabling the design of complex network architectures with improved precision and efficiency. This research utilized a dataset focused on the environmental and control parameters of tomato plants. The tomato seeds were cultivated in stone wool beds using hydroponic techniques. An innovative deep neural network structure was proposed in this study to achieve automatic microclimate control in greenhouses.

### Results

The developed deep learning-based model predicted the temperature, relative humidity, and carbon dioxide concentration inside the greenhouse with coefficients of determination of 0.81, 0.61, and 0.85, respectively. The temperature in the greenhouse was predicted with good accuracy by the deep neural network model, demonstrating better results with less variation. Additionally, the relative humidity was maintained within a lower range, effectively preventing fungal growth. A similar trend was observed between deep learning models and dynamical mathematical models in predicting CO<sub>2</sub> concentration. Artificial intelligence (AI) models offer several advantages, including the ability to make decisions over an unlimited forecasting horizon without relying on prior models, high inherent stability, adaptability, and low complexity in real-time training. AI models can analyze vast amounts of input data and identify complex patterns that may not be easily discernible using traditional system dynamics approach. This capability enables accurate predictions and optimized control of greenhouse environmental conditions, facilitating improved plant growth. AI models can adapt to and learn from new data, continuously enhancing their predictive capabilities over time. Their dynamic and responsive predictions support better decision-making processes. Ultimately, deep learning models can conduct a comprehensive analysis of multiple variables simultaneously, considering numerous influential factors such as temperature, humidity, light levels, and carbon dioxide concentration. This approach not only reduces costs but also enhances overall efficiency.

### Conclusion

This research proposed a deep learning-based approach to predict greenhouse environmental conditions for tomato production. The exceptional performance of the deep neural network model was attributed to its structural design for pattern recognition and the precise data collected from a greenhouse managed by expert operators. Dynamic models play a crucial role in illustrating the effects of parameters on the greenhouse microclimate and in modeling product growth. They are especially valuable when setting up a greenhouse in a new geographical location without the availability of expert knowledge. In the future, other deep learning models and optimization algorithms could be employed to reduce production costs and optimize energy consumption by utilizing data from various geographical locations.

### Author Contributions

Conceptualization, H.G., S.S.M. and R.A.; methodology, H.G.; software, H.G.; validation, H.G. and R.A.; formal analysis, H.G.; investigation, H.G. and R.A.; resources, H.G. and R.A.; writing—original draft

preparation, H.G., S.S.M., R.A. and M.H.; writing—review and editing, R.A. and M.H.; supervision, R.A. and S.S.M.; project administration, R.A.; funding acquisition, R.A..

**Data Availability Statement**

Data sets generated during the current study are available from <https://doi.org/10.4121/uuid:88d22c60-21b3-4ea8-90db-20249a5be2a7>.

**Acknowledgements**

The authors express their gratitude to the University of Tehran for providing essential resources to facilitate this research.

**Ethical considerations**

The study was approved by the Ethics Committee of the University of ABCD (Ethical code: IR.UT.RES.2024.500). The authors avoided data fabrication, falsification, plagiarism, and misconduct.

**Conflict of interest**

The author declares no conflict of interest.

## پیش‌بینی پارامترهای محیطی گلخانه با استفاده از الگوریتم یادگیری عمیق

هژیر ع قادری<sup>۱</sup> | رضا علیمردانی<sup>۲</sup> | سید سعید محتسبی<sup>۳</sup> | محمد حسین پور زرنق<sup>۴</sup>

۱. گروه مهندسی ماشین‌های کشاورزی، دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران، دانشگاه تهران، کرج، ایران. رایانامه:

[hajir.ghaderi1991@gmail.com](mailto:hajir.ghaderi1991@gmail.com)

۲. نویسنده مسئول، گروه مهندسی ماشین‌های کشاورزی، دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران، دانشگاه تهران، کرج، ایران.

رایانامه: [rmardani@ut.ac.ir](mailto:rmardani@ut.ac.ir)

۳. گروه مهندسی ماشین‌های کشاورزی، دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران، دانشگاه تهران، کرج، ایران. رایانامه:

[mohtaseb@ut.ac.ir](mailto:mohtaseb@ut.ac.ir)

۴. گروه مهندسی ماشین‌های کشاورزی، دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران، دانشگاه تهران، کرج، ایران. رایانامه:

[husenpour@ut.ac.ir](mailto:husenpour@ut.ac.ir)

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	ایجاد شرایط مناسب به جهت رشد گیاه در گلخانه نیازمند صرف کردن منابع و هزینه‌های عملیاتی است. به‌منظور مدیریت صحیح و صرفه‌جویی در مصرف منابع و هزینه‌ها در گلخانه، کنترل شرایط محیطی بایستی به شکل کارآمد و اثربخشی صورت بپذیرد. روش مبتنی بر مدل دینامیکی با توجه به قدمت و برخورداری از ماهیت ریاضی پیوسته مورد توجه محققان در حوزه کنترل شرایط محیطی گلخانه بوده است. در این تحقیق، یک سامانه پیش‌بینی شرایط محیطی برای گلخانه شیشه‌ای با استفاده از یادگیری عمیق طراحی شد. روش توسعه داده شده در مهیا کردن شرایط دقیق در تولید محصول گوجه‌فرنگی در گلخانه شیشه‌ای انجام شد. مدل توسعه داده شده مبتنی بر یادگیری عمیق پیش‌بینی دما، رطوبت نسبی و غلظت دی‌اکسید کربن داخل گلخانه را بر اساس ورودی‌های سرعت باد، دمای مجازی آسمان، میزان تابش فعال فتوسنتزی، تابش جمعی، دما، رطوبت نسبی و غلظت دی‌اکسید کربن بیرون با ضریب تبیین ۰/۸۱، ۰/۶۱ و ۰/۸۵ انجام داد. شبکه عصبی عمیق به دلیل استفاده از داده‌های عملیاتی گلخانه تحت کنترل کارشناسان خبره دارای عملکرد مناسب بود و نسبت به مدل‌های دینامیکی مزایای امکان به‌کارگیری بدون نیاز به مدل قبلی، تصمیم‌گیری پیوسته و بلندمدت برای شرایط محیطی بر اساس نیازهای گیاه، پایداری ذاتی بالا، سازگاری بالا و پیچیدگی کم در آموزش بالادرنگ را مهیا می‌کند. بر این اساس روش‌های دقیق مبتنی بر هوش مصنوعی می‌توانند به انتخاب بهترین راهکار در راستای حل مسئله کنترل پهنه گلخانه برای افزایش عملکرد و کاهش هزینه بیانجامد.
تاریخ دریافت: ۱۴۰۳/۱۰/۱۶	
تاریخ بازنگری: ۱۴۰۴/۱/۲	
تاریخ پذیرش: ۱۴۰۴/۱/۱۹	
تاریخ انتشار: زمستان ۱۴۰۳	
واژه‌های کلیدی: گلخانه هوشمند، هوش مصنوعی، مدل‌های شبیه‌سازی.	

استناد: ع قادری، هژیر؛ علیمردانی، رضا؛ محتسبی، سید سعید و حسین پور زرنق، محمد (۱۴۰۴). پیش‌بینی پارامترهای محیطی گلخانه با استفاده از الگوریتم یادگیری عمیق،

مجله مهندسی بیوسیستم ایران/ ایران، ۵۵ (۴)، ۶۳-۷۹. <https://doi.org/10.22059/ijbse.2025.388236.665578>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijbse.2025.388236.665578>

## مقدمه

گلخانه یک سیستم باغبانی پیشرفته به منظور تأمین غذای بشر و یکی از روش‌های دستیابی به کشاورزی پایدار به شمار می‌آید. رشد جمعیت، تقاضای بیشتر برای غذا و تغییرات آب‌وهوایی باعث فشار بر منابع آب شده به نحوی که تولیدات کشاورزی ۸۵ درصد از مصرف جهانی آب را به خود اختصاص داده است (G. He et al., 2021; L. He et al., 2021). از طرف دیگر، تولید بیشتر محصولات کشاورزی نیازمند افزایش سطح زیر کشت بوده به طوری که با وجود کشت بر روی ۱۱ درصد سطح کره زمین عملاً افزایش سطح زیر کشت دشوار به نظر می‌رسد (Klarin et al., 2019); علاوه بر مورد فوق، کشاورزی غیراصولی سبب کاهش تنوع زیستی، قحطی، فرسایش خاک و تولید حجم وسیعی از دی‌اکسید کربن شده است و به طور کلی این موارد بشر را به سمت یافتن روشی پایدار در جهت تأمین مواد غذایی سوق داده است. یکی از راهکارهایی که در حال حاضر در راستای کشاورزی پایدار پیشنهاد شده و به شدت طی چند دهه اخیر رو به رشد بوده کشت گلخانه‌ای است و مطابق با برخی آمارهای موجود در حال حاضر ۳/۶۴ میلیون هکتار گلخانه در سطح جهان احداث شده است (McNulty, 2017). البته کشت‌های درون گلخانه نیازمند مدیریت بهینه و دقیق بوده که این مهم با معرفی سامانه‌های جدید اندازه‌گیری و مدیریت اطلاعات امکان‌پذیر است (Konig et al., 2012). بر اساس نتایج حاصل از آمارگیری تعداد گلخانه‌های کشور در سال ۱۳۹۹، تعداد ۲۲۴۷۷ گلخانه در سطح کشور وجود داشته که از این تعداد، ۲۰۶۳۲ واحد فعال و ۱۸۴۵ واحد غیرفعال هستند. نتایج حاصل از این طرح نشان داد مساحت گلخانه‌های کشور در سال ۱۳۹۹ بیش از ۹۸۰۰ هکتار بوده (مرکز آمار ایران، ۱۳۹۹) که البته این آمار با توجه به طرح‌های توسعه‌ای موجود در وزارت جهاد کشاورزی پیوسته رو به رشد است. فراهم آوردن امکانات سخت‌افزاری احداث گلخانه‌های مدرن و هوشمند اگرچه سخت اما امکان‌پذیر بوده ولی چیزی که خلأ آن احساس می‌گردد چگونگی کنترل متغیرهای محیطی داخل گلخانه بر اساس اقلیم کشور است. هزینه‌های سخت‌افزاری کنترل هوشمند شرایط محیطی گلخانه شامل حس‌گرها و دستگاه‌های اندازه‌گیری (شامل دما، رطوبت، نور و CO<sub>2</sub> و آبیاری)، شبکه‌های ارتباطی برای انتقال داده‌ها از حس‌گرها به سیستم‌های پردازشی، سیستم‌های پردازشی (شامل سرورها و کامپیوتر برای پردازش داده‌ها و اجرای الگوریتم‌ها) و سیستم کنترلی اجزای مکانیکی شامل پی ال سی و کنترلرها است. این روش در مقایسه با روش‌های سنتی هزینه‌های نرم‌افزاری و سخت‌افزاری اولیه برای کشاورزان و مدیران به همراه دارد. البته مزیت زمان بازگشت سرمایه با افزایش عملکرد و بهره‌وری محصول با مهیا ساختن شرایط رشد بهینه به همراه کاهش هزینه‌های انرژی و بهینه‌سازی مصرف انرژی گرمایش، سرمایش و نورپردازی و تزریق گاز CO<sub>2</sub> و مصرف آب جبران می‌شود. همچنین کیفیت محصولات با کنترل دقیق‌تر شرایط محیطی بهبود یافته و ارزش افزوده بیشتری ایجاد می‌شود. لازم به ذکر است پیشرفت تکنولوژی و کاهش هزینه‌های سخت‌افزاری نسبت به هزینه‌ها امروزه این سیستم‌ها را در گلخانه مدرن فراگیر کرده است.

به طور کلی مدل‌های مختلفی از جمله مدل‌های دینامیکی، مدل‌های جعبه سیاه و مدل‌های شبکه عصبی به منظور پیش‌بینی و کنترل شرایط محیطی گلخانه و رشد گیاه ارائه شده‌اند. مدلی دینامیکی که خود از ارکان اساسی روش کنترل پیش‌بین مبتنی بر مدل است، بر اساس معادلات موازنه جرم و انرژی حاکم بر محیط داخلی گلخانه است. ایده اول کنترل پیش‌بین مبتنی بر مدل که از آن پس جهت اختصار کنترل پیش‌بین نامیده می‌شود، در اواخر دهه ۱۹۷۰ میلادی در صنعت پتروشیمی شکل گرفت و با توجه به کاربردی که داشت به سرعت در صنایع دیگر نیز به کار گرفته شد. در یک تحقیق با آنالیز حساسیت، یک مدل دینامیکی از اقلیم گلخانه را مشخص نمودند که دما و رطوبت داخل گلخانه از پارامترهایی مانند نسبت سطح پوشش گلخانه به سطح کف گلخانه، میزان جذب تشعشع گیاه، ضریب انتقال حرارت جابجایی هوای داخل و سطح گلخانه و میزان نفوذ هوا در گلخانه ارتباط دارد (Chalabi & Bailey, 1991). در تحقیقی با استفاده از یک سری معادلات دیفرانسیل مرتبه اول موازنه جرم و انرژی داخل گلخانه تبیین شد (Bot, 1991). او در این مطالعه با نوشتن معادلات حالت حاکم بر گلخانه و حل دستگاه معادلات دیفرانسیل تشکیل شده نسبت به زمان، پارامترهای تخمین دمای محیط و گیاه در شرایط گذرای گلخانه با توجه به نرخ تهویه، میزان تبخیر و تعریق گیاه، انتقال حرارت جابجایی میان سطح و هوای بیرون گلخانه، انتقال حرارت میان سامانه گرمایش و محیط داخل، انتقال حرارت میان محیط گلخانه و سطح خاک تعیین نمود.

هیوولینک در سال ۱۹۹۶ به بررسی ارتباط میان رشد گیاه با شرایط محیطی (نور، دما و غلظت دی‌اکسید کربن) و مدیریت گیاه (تراکم گیاه و میزان برداشت میوه) پرداخت (Heuvelink, 1996). وی در مدل ارائه شده تانسیم ظرفیت رشد گیاه بر اساس پارامترهایی از جمله نرخ فتوسنتز برگ، میزان نور در دسترس برای گیاه، بازدهی تبدیل کربوهیدرات به ماده خشک و نرخ تعریق گیاه، شبیه‌سازی کرد.

بر اساس موازنه جرم و انرژی در گلخانه، یکی از کامل‌ترین مدل‌ها تا به امروز در پژوهش دزوارت در سال ۱۹۹۶ ارائه شد (De Zwart, 1996). مدل مذکور برای گلخانه‌های شیشه‌ای هلندی توسعه یافته و رابط گرافیکی آن شبیه به نرم‌افزارهای تجاری کنترل گلخانه است. یکی از ویژگی‌های این مدل توانایی آن در کمک به افراد در جهت تصمیم‌گیری در مورد روش کنترل اقلیم گلخانه است. به علاوه این مدل می‌تواند به منظور ارزیابی شرایط احداث گلخانه نیز به کمک متخصصان امر بیاید. در یکی از کامل‌ترین مطالعات در زمینه طراحی گلخانه به کمک مدل‌سازی دینامیکی دمای داخل گلخانه برحسب دمای بیرون، استراتژی‌های مدیریت دما و نوع سازه گلخانه ارائه شد (Vanthoor, 2011). یکی از مزایای این مدل جامع بودن آن بود، به طوری که به کمک آن این امکان وجود داشت گلخانه‌هایی در نواحی مختلف آب‌وهوایی شبیه‌سازی شود. اعتبارسنجی نتایج این مدل در سه گلخانه با شرایط آب‌وهوای معتدل اقیانوسی (هلند)، مدیترانه‌ای (اسپانیا) و نیمه‌خشک (چین) از تطابق خوبی برخوردار بود (Vanthoor, 2011; Vanthoor, Stanghellini, et al., 2011).

با توجه به اهمیت فرآیند رشد گیاه در کنترل اقلیم گلخانه مدلی فیزیکی نیز برای فرآیند رشد گیاه گوجه‌فرنگی ارائه شده است (Vanthoor et al., 2011). در مطالعه‌ای بر روی سازه‌های هلندی و با در نظر گرفتن توابع هدف کاهش مصرف انرژی، کاهش مصرف آب، کاهش مصرف دی‌اکسید کربن و در نهایت کاهش هزینه‌های عملیاتی با در نظر گرفتن دما، رطوبت و دی‌اکسید کربن داخل گلخانه در یک محدوده مشخص شد که هدف آن کاهش هزینه‌های عملیاتی بهترین تابع هدف (افق دید) است (Lin et al., 2021). سگینر یکی دیگر از پیشگامان استفاده از هوش مصنوعی در کنترل گلخانه بود و با طراحی یک شبکه عصبی با یک لایه مخفی، رابطه میان متغیرهای داخلی و خارجی گلخانه را پیش‌بینی کرد (Seginer, 1997; Seginer et al., 1994). در این راستا متغیرهای کنترل عملکرد سامانه گرمایش و تهویه با در نظر گرفتن میزان تابش خورشید و دمای حباب تر و خشک با داده‌هایی مربوط به بازه سال‌های ۱۹۸۹ تا ۱۹۹۱ مدل‌سازی شدند. نتایج دارای خطای بالایی بود و محققین گزارش کردند که در زمان استفاده از شبکه‌های عصبی می‌بایست کلیه تجهیزات و ادوات گلخانه درست عمل کرده و نقص در عملکرد آن‌ها موجب مشکلاتی در مدل‌سازی خواهد شد. علاوه بر تغییر در نوع سازه و روش‌های تنظیم شرایط محیطی سبب ایجاد خطا در مدل خواهد داشت.

در مطالعه‌ای مدل مبتنی بر شبکه عصبی پایه شعاعی برای پیش‌بینی دمای داخل گلخانه‌ای هیدروپونیک بر اساس رطوبت نسبی داخل، دمای محیط خارج و میزان تشعشع دریافتی گلخانه معرفی شد که نسبت به روش پرسپترون چندلایه ساده‌تر است (Ferreira et al., 2002). وانگ و همکاران الگوریتمی برای پایه ماشین بردار پشتیبان ارائه نمود که وزن‌های آن به صورت بر خط به‌روزرسانی شده و علاوه بر عمومیت و سهولت در به‌کارگیری از توانایی بالایی در آموزش پدیده‌های غیرخطی مانند شرایط آب‌وهوای گلخانه را داشت (Wang et al., 2009). به کمک شبکه عصبی پایه شعاعی تنظیم پارامترهای یک کنترل‌گر تناسبی-مشتق‌گیر نسبت به روش‌های ساده تنظیم پارامترهای این نوع از کنترل‌گرها نتایج بهتری در کنترل عوامل محیطی گلخانه از خود نشان داد (Hu et al., 2011). در تحقیقی دیگر با استفاده از شبکه عصبی پایه شعاعی برای تنظیم پارامترهای یک کنترل‌گر تناسبی-انتگرال‌گیر-مشتق‌گیر به منظور کنترل اقلیم گلخانه برای مقایسه کنترل برخط با روش با وقفه طراحی شد که در نهایت روش برخط بهبود جالب توجهی در تعیین نقاط تنظیم پارامترها و در کاهش نوسان در تنظیم را نشان داد (Zeng et al., 2012).

در سال‌های اخیر با توجه به پیشرفت در حوزه‌های مختلف یادگیری ماشین، استفاده از روش‌های جدید در کنترل اقلیم گلخانه مورد استقبال پژوهشگران قرار گرفته است. یکی از این روش‌ها، یادگیری عمیق بوده که نیازمند حجم بالایی از داده است؛ این امر با توجه به توسعه فناوری در داده‌برداری و انتقال سریع و لحظه‌ای آن امکان‌پذیر شده است. از ترکیب شبکه‌های کانولوشنی و شبکه‌های عصبی بازگشتی مدلی برای رشد گیاه که یکی از پارامترهای مهم در کنترل اقلیم گلخانه است، استفاده شده است (Gong et al., 2021). در تحقیقی بر روی کنترل یک گلخانه نیمه بسته در شهر نیویورک به کمک روش یادگیری تقویتی عمیق میزان مصرف انرژی در روش یادگیری تقویتی عمیق بیش از ۵۰ درصد کاهش یافت ضمن اینکه زمان محاسبات نسبتاً کمتری نیز جهت یادگیری شبکه صرف شد (Ajagekar & You, 2022). یادگیری عمیق برای پیش‌بینی عملکرد و تغییرات رشد گیاه گوجه‌فرنگی در محیط‌های گلخانه‌ای با شبکه عصبی بازگشتی (RNN) و مدل حافظه طولانی کوتاه‌مدت (LSTM) استفاده شده است (Alhnaity et al., 2019). توسعه مدل‌هایی که می‌توانند به طور مؤثر رشد و عملکرد را مدل‌سازی کنند، می‌تواند به تولیدکنندگان کمک کند تا کنترل محیطی را برای تولید بهتر، مطابقت با عرضه و تقاضای بازار و هزینه‌های پایین‌تر انجام دهند. در تحقیقی دیگر بر روی گلخانه خورشیدی مدل شبکه عصبی کانولوشنی-حافظه طولانی کوتاه‌مدت عملکرد بالایی در پیش‌بینی دما و رطوبت نسبی نشان داد (Jia & Wei, 2022). در حالی که تحقیقات موجود استفاده

از مدل‌های یادگیری عمیق را در پیش‌بینی ریز اقلیم‌های گلخانه‌ای مورد بررسی قرار داده‌اند، شکاف‌های تحقیقاتی قابل توجهی وجود دارد (Jung et al., 2020; Shi et al., 2024). اثربخشی این مدل‌ها، به‌ویژه در تحلیل روابط پیچیده مکانی-زمانی در انواع گلخانه نیاز به بررسی بیشتر دارد. به همان اندازه نیاز به اطلاعات واقعی در محیط‌های کشاورزی گلخانه‌ای معتبر است. بنابراین، نیاز به کاوش جامع‌تر مدل‌ها در رویارویی با اطلاعات واقعی تولید و بررسی عملکرد آن در سناریوهای کشاورزی است.

هدف این تحقیق به‌طور کلی پیش‌بینی شرایط محیطی داخل گلخانه با استفاده از الگوریتم‌های مبتنی بر هوش مصنوعی بجای روش کنترل پیش‌بین یا همان مدل‌های دینامیکی به‌عنوان یک روش قدیمی‌تر در کنترل فرآیندهای صنعتی است که مورد استفاده قرار می‌گیرد. همچنین الگوریتم‌های کلاسیک اغلب از رویکرد مدل واحد برای پیش‌بینی همه متغیرهای مورد مطالعه استفاده می‌کنند که منجر به پیش‌بینی‌های نامتعادل می‌شود که در آن برخی از متغیرها به طور دقیق و برخی دیگر با قطعیت کمتر پیش‌بینی شوند. بر این اساس در این تحقیق با استفاده از یادگیری عمیق هر یک از پارامترهای شرایط محیطی گلخانه با توجه به شرایط واقعی داخل (خروجی سامانه) و تغییر شرایط محیطی و همچنین اغتشاشات وارد شده ارزیابی می‌شود که در نهایت بتوان مزایا و محدودیت‌های این رویکرد را در کنترل گلخانه‌های مدرن و هوشمند سنجید.

## مواد و روش‌ها

### آماده‌سازی داده‌ها

هرساله رقابت‌هایی در حوزه خودکارسازی گلخانه‌ها و استفاده از فناوری‌های نوین در گلخانه‌ها در دانشگاه واخنینگن و در شهر بلیسویک برگزار می‌گردد. برگزارکنندگان دیتاست‌های به‌دست‌آمده را به منظور توسعه فناوری‌های مبتنی بر هوش مصنوعی در اختیار عموم قرار می‌دهند (Hemming et al., 2019, 2020).

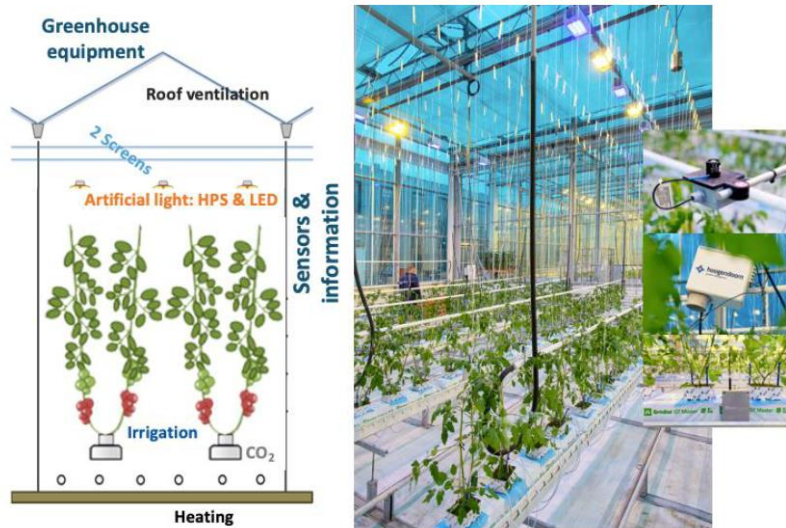
به منظور آموزش شبکه یادگیری عمیق در این پژوهش از دیتاست مربوط به پارامترهای محیطی و کنترلی گیاه گوجه‌فرنگی استفاده شد (Hemming et al., 2020). این دیتاست‌ها مربوط به چند گلخانه کنار هم که همگی توسط گروه‌های شرکت کننده در رقابت و یک گروه خبره از کارشناسان کنترل می‌شدند، تهیه شده است. با توجه به نتایج مشاهده‌شده دیتاست تولید شده از گلخانه کنترل شده توسط کارشناسان خبره دقیق‌تر ارزیابی شد و به همراه دیتاست تولید شده توسط تیم برنده به‌عنوان مرجع آموزش شبکه یادگیری عصبی عمیق در این پژوهش استفاده گردید.

محل آزمایش‌های صورت گرفته در دانشگاه واخنینگن و زمان آن ۱۶۵ روز (از دسامبر سال ۲۰۱۹ تا آوریل سال ۲۰۲۰) بود. گلخانه مذکور از نوع ونلو و مساحت آن ۹۶ مترمربع بوده که تجهیزات به کار گرفته شده در آن عبارت‌اند از:

- سامانه گرمایش لوله‌های زمینی و لوله‌های نزدیک به گیاه آویزان شده
- پنجره‌های یکپارچه بر روی سقف به جهت تهویه
- سامانه تزریق گاز کربن دی‌اکسید
- پرده‌های ذخیره‌سازی و بهینه‌سازی مصرف انرژی
- سامانه نور مصنوعی

علاوه بر موارد فوق بذره‌های گوجه‌فرنگی در بستر پشم سنگ کاشته شده و نوع کشت به‌صورت هیدروپونیک در نظر گرفته شده است (شکل ۱).



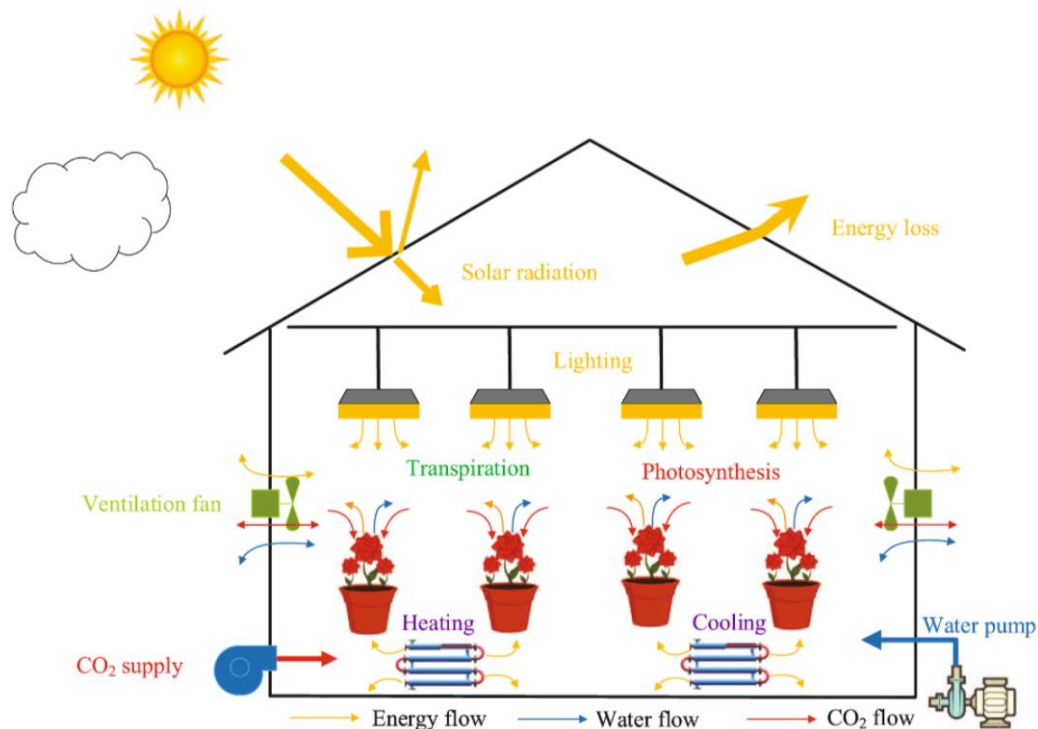


شکل ۱. گلخانه مورد استفاده جهت برداشت دیتاست‌های این پژوهش.

#### مدل دینامیکی حاکم بر محیط گلخانه

در مدل‌سازی سامانه‌های دینامیکی تلاش می‌شود تا یک مدل ریاضی مناسب برای توصیف عملکرد یک سامانه به دست آید و سپس با توجه به آن کنترل‌کننده طراحی شود. معمولاً به منظور فراهم آوردن شرایط مناسب جهت رشد گیاه در گلخانه از سامانه‌های سرمایش و گرمایش، تهویه اجباری و آزاد، تزریق دی‌اکسید کربن و تنظیم نور مورد نیاز جهت رشد گیاه استفاده می‌شود. به‌طور کلی در نظر گرفتن کلیه تجهیزات مورد استفاده در یک گلخانه بر پیچیدگی‌های مدل می‌افزاید؛ بنابراین بهتر است تجهیزات و پارامترهای اثرگذار سامانه انتخاب شده و مدنظر قرار گیرد.

در پژوهش (Lin et al., 2021) مدلی ارائه شد که در یک گلخانه صنعتی نیز به کار گرفته شده است و الگوی برهم‌کنش تجهیزات در آن در شکل ۲. مشاهده می‌گردد.



شکل ۲. برهم‌کنش عوامل فیزیکی در گلخانه

با توجه به آنچه گفته شد، معادلات بیان‌کننده موازنه انرژی، آب، غلظت دی‌اکسید کربن به همراه مدل مصرف آب توسط گیاه در



ادامه به شرح زیر است:

### انرژی و دما

یکی از مهم‌ترین شاخصه‌ها بر روی رشد گیاه در گلخانه دمای گلخانه است که از عوامل مختلف محیطی تأثیر می‌پذیرد و موازنه آن در رابطه (۱) بیان شده است:

$$\frac{dT_{in}}{dt} = \frac{1}{C_{cap}}(Q_{sun} + Q_{lamp} - Q_{cov} - Q_{trans} - Q_{vent} + Q_c) \quad \text{رابطه (۰)}$$

در رابطه (۱)،  $C_{cap}$  ظرفیت گرمایی گلخانه،  $Q_{sun}$  تشعشع دریافتی از جانب خورشید،  $Q_{lamp}$  انرژی دریافتی از جانب نور مصنوعی است.  $Q_{cov}$  تبادل حرارت میان گلخانه با محیط اطراف از طریق پوسته گلخانه و  $Q_{trans}$  انرژی جذب شده از طریق تبخیر و تعرق گیاه می‌باشد.  $Q_c$  و  $Q_{vent}$  به ترتیب تغییرات انرژی از طریق تهویه و توان مصرفی به جهت سرمایش و گرمایش در گلخانه را بیان می‌کنند.  $Q_{sun}$  از طریق رابطه (۲) به دست می‌آید:

$$Q_{sun} = \alpha_1(1 - s_r)I_{glob} \quad \text{رابطه (۰۲)}$$

$I_{glob}$  تابش جهانی تجمعی خارج از گلخانه (میزان کل انرژی تابشی که از خورشید به سطح زمین می‌رسد) و  $\alpha_1$  ضریب عبور نور از پوسته گلخانه است.  $s_r$  میزان باز یا بسته بودن پرده‌های صرفه‌جویی در انرژی بوده که توسط سامانه مربوطه تنظیم می‌گردد.  $Q_{cov}$  به صورت رابطه (۳) بیان می‌شود (Van Henten, 2003):

$$Q_{cov} = \alpha_2(T_{in} - T_{out}) \quad \text{رابطه (۰)}$$

$\alpha_2$  ضریب انتقال حرارت پوسته گلخانه و  $T_{out}$  دمای بیرون گلخانه است.

$Q_{trans}$  از طریق رابطه (۴) محاسبه می‌گردد:

$$Q_{trans} = g_e L(H_{crop} - H_{air}) \quad \text{رابطه (۰۴)}$$

در رابطه (۴)،  $g_e$  ضریب رسانایی تبخیر،  $L$  انرژی مورد نیاز جهت بخار شدن آب از برگ،  $H_{crop}$  مقدار مطلق بخار آب در گیاه و  $H_{air}$  مقدار مطلق بخار آب در هوای گلخانه است.  $g_e$  از رابطه (۵) قابل محاسبه است.

$$g_e = \frac{2LAI}{(1 + \varepsilon)r_b + r_s} \quad \text{رابطه (۰)}$$

$LAI$  شاخص سطح برگ،  $\varepsilon$  نسبت گرمای نهان به گرمای محسوس هوای اشباع محیط گلخانه است.  $r_b$  مقاومت لایه مرزی و  $r_s$  مقاومت منافذ جذب هوای گیاه است.  $H_{crop}$  نیز از رابطه (۶) قابل محاسبه است.

$$H_{crop} = H_{air.sat} + \varepsilon \frac{r_b}{2LAI} \frac{R_n}{L} \quad \text{رابطه (۰۶)}$$

در رابطه (۶)، مقادیر  $H_{air.sat}$ ،  $\varepsilon$  و  $r_s$  به صورت رابطه‌های (۷-۹) بیان می‌شوند.

$$H_{air.sat} = 5.5638e^{0.0518T_{air}} \quad \text{رابطه (۰۷)}$$

$$\varepsilon = 0.7584e^{0.0572T_{air}} \quad \text{رابطه (۰۸)}$$

$$r_s = (82 + 570e^{-\frac{7R_n}{LAI}})(1 + 0.023(T_{in} - 20)^2) \quad \text{رابطه (۰۹)}$$

$\zeta$  شاخصه گیاه است و  $R_n$  مقدار تشعشع جذب شده توسط گیاه است.

$$R_n = 0.86(1 - e^{-0.7LAI})(Q_{sun} + P_E) \quad \text{رابطه (۱۰)}$$

$P_E$  توان لامپ‌های روشنایی است بنابراین:

$$Q_{lamp} = \eta P_E \quad \text{رابطه (۰۱۱)}$$

$\eta$  میزان تبدیل توان لامپ به گرما است.

$$Q_{vent} = g_v \rho_{air} C_{p.air}(T_{in} - T_{out}) \quad \text{رابطه (۰)}$$

در رابطه (۱۲)،  $g_v$  نشان‌دهنده نرخ تهویه ویژه،  $\rho_{air}$  چگالی هوا و  $C_{p.air}$  ظرفیت حرارتی هوا است.

### رطوبت نسبی

علاوه بر دما، رطوبت نسبی نیز از تأثیر به سزایی در رشد و ماندگاری گیاه دارد. رطوبت نسبی در گلخانه تحت تأثیر میزان تبخیر و تعرق گیاه، بخار آب چگالیده و تهویه شده قرار دارد.

$$RH_{air} = H_{air}/H_{air.sat} \quad \text{رابطه ۰۱۳}$$

$H_{air}$  غلظت بخار در هوای گلخانه را نشان می‌دهد.  $H_{air}$  از طریق رابطه زیر محاسبه می‌شود:

$$\frac{dH_{air}}{dt} = \frac{1}{h}(H_{trans} - H_{cov} - H_{vent}) \quad \text{رابطه ۰۱۴}$$

در رابطه (۱۴)،  $H_{trans}$  میزان بخاری است که از طریق تبخیر و تعرق گیاه تولید می‌شود،  $H_{cov}$  میزان بخار آب چگالیده شده بر روی پوسته داخلی گلخانه است و  $H_{vent}$  شار بخاری است که از طریق تهویه خارج می‌گردد.  $H_{trans}$  از دو شاخصه  $H_{crop}$  و  $H_{air}$  تأثیر می‌پذیرد و به صورت رابطه (۱۵) بیان می‌شود.

$$H_{trans} = g_e(H_{crop} - H_{air}) \quad \text{رابطه ۰۱۵}$$

$H_{cov}$  از رابطه زیر به دست می‌آید:

$$H_{cov} = g_c[0.2522e^{0.0485T_{air}}(T_{in} - T_{out}) - (H_{air} - H_{air.sat})] \quad \text{رابطه ۰۱۶}$$

$g_c$  میزان چگالش آب بوده و از طریق رابطه (۱۷) محاسبه می‌گردد.

$$g_c = \begin{cases} 0 & \text{If } T_{in} \leq T_{out} \\ p_{gc}(T_{in} - T_{cov})^3 & \text{If } T_{in} > T_{out} \end{cases} \quad \text{رابطه ۰۱۷}$$

$p_{gc}$  با ظرفیت چگالش آب بر روی سطح مربوطه متناسب است.

$H_{vent}$  نیز از میزان نرخ تهویه و رطوبت نسبی داخل و خارج گلخانه تأثیر می‌پذیرد.

$$H_{vent} = g_v(H_{air} - H_{out}) \quad \text{رابطه ۰۱۸}$$

$g_v$  نرخ تهویه است که در مدل مورد استفاده شده از طریق توان فن‌ها کنترل می‌شود.

### غلظت دی‌اکسید کربن

با توجه به اینکه میزان فتوسنتز گیاه نسبت مستقیمی با میزان کربن دی‌اکسید در دسترس گیاه دارد بنابراین این شاخصه از مهم‌ترین شاخصه‌های درون هر گلخانه‌ای به شمار می‌آید. در شیوه کشت نوین با تزریق کربن دی‌اکسید و کنترل آن عملاً میزان رشد گیاه نیز افزایش داده می‌شود. مدل کربن دی‌اکسید در گلخانه در رابطه زیر نشان داده شده است:

$$\frac{dC_{air}}{dt} = \frac{1}{h}(C_{inj} - C_{ass} - C_{vent}) \quad \text{رابطه ۰۱۹}$$

$C_{air}$  میزان کربن دی‌اکسید درون گلخانه،  $C_{inj}$  نرخ تزریق کربن دی‌اکسید در محیط،  $C_{ass}$  میزان مصرف کربن دی‌اکسید و  $C_{vent}$

میزان کربن دی‌اکسید خارج شده از طریق تهویه است.  $C_{vent}$  و  $C_{inj}$  به ترتیب از روابط (۲۱-۲۰) به دست می‌آیند:

$$C_{ass} = 2.2 \times 10^{-3} \frac{1}{1 + \frac{0.42}{C_{air}}} (1 - e^{0.003(Q_{sun} - PE)}) \quad \text{رابطه ۰۲۰}$$


$$C_{vent} = g_v(C_{air} - C_{out}) \quad \text{رابطه ۰۲۱}$$

### طراحی سامانه یادگیری عمیق برای کنترل آب و هوا در گلخانه

در کنترل اتوماتیک آب و هوای گلخانه به کمک هوش مصنوعی به کمک پارامترهایی قابل اندازه‌گیری انجام می‌گیرد. هدف نهایی طراحی مدل‌هایی است که پیش‌بینی‌ها را با دقت بالایی انجام داد که بتوان از آن در کاهش هزینه‌ها استفاده کرد. شبکه عصبی عمیق شبیه‌ساز شرایط محیطی داخل گلخانه متشکل از ورودی‌های سرعت باد، میزان تابش، میزان تابش فعال فتوسنتزی، تشعشع قابل دسترس به جهت فتوسنتز، دما، رطوبت نسبی و غلظت دی‌اکسید کربن بیرون گلخانه و خروجی شبکه شامل دما، رطوبت و غلظت دی‌اکسید کربن داخل بوده که توسط سه لایه میانی یا پنهان Dense به یکدیگر مرتبط می‌شوند (جدول ۱). در لایه اول و دوم شبکه ۳۰۰ نورون و در لایه سوم آن ۶۰۰ نورون در نظر گرفته شده است (شکل ۳). تعداد لایه و نیز تعداد نورون‌ها با آزمون و خطا و آزمایش حالت‌های مختلف انتخاب شد. لازم به ذکر است پارامترهای برای نرخ آموزش شبکه برابر ۰/۰۱، تعداد دوره‌ها برابر ۱۵۰ و اندازه دسته‌ها برابر ۵۱۲ در نظر گرفته شد.

جدول ۱. متغیرهای ورودی در مدلسازی شرایط محیطی گلخانه.

واحد	توضیحات	نام متغیر	دسته بندی
$W/m^2$	میزان تابش جهانی تجمعی خارج <sup>۱</sup>	$I_{glob}$	آب‌وهوای بیرون گلخانه (w)
$^{\circ}C$	دمای بیرون	$T_{out}$	
%	رطوبت نسبی بیرون	$RH_{out}$	
$ppm$	غلظت دی‌اکسید کربن بیرون	$CO_2 out$	آب‌وهوای داخل گلخانه (c)
$m/s$	سرعت باد	<b>Wind Speed</b>	
$^{\circ}C$	دمای مجازی آسمان	$T_{sky}$	
$\mu mol/s$	میزان تابش یا تشعشعات فتوسنتزی <sup>۲</sup>	$PAR$	
$^{\circ}C$	دمای داخل	$T_{in}$	
%	رطوبت نسبی داخل	$RH_{in}$	
$ppm$	غلظت دی‌اکسید کربن داخل	$CO_2 in$	



شکل ۳. معماری شبکه عصبی شبیه‌ساز آب‌وهوای داخل گلخانه.

شبکه فوق میانگین مربعات خطا در فرایند آموزش شبکه در نظر گرفته شد که به کمک رابطه (۲۲) بیان می‌گردد:

$$\mathcal{L}(\Theta_1) = \frac{1}{N} \sum_{i=1}^N \sum_{k=1}^4 (\hat{c}_i^{(k)} - c_i^{(k)})^2 \quad \text{رابطه (۱)}$$


در رابطه (۲۲)،  $\mathcal{L}(\Theta_1)$  خطا در N نمونه از داده و  $\hat{c}_i^{(k)}$  و  $c_i^{(k)}$  به ترتیب نشان‌دهنده مقدار واقعی و پیش‌بینی شده متغیر آب‌وهوایی k ام در نمونه i ام هستند. شبکه فوق به کمک داده‌های به دست آمده از دیتاستی که در بخش قبل توضیح داده شد آموزش داده شد. در این پژوهش جهت پردازش از سرور ۱۶ هسته‌ای مرکز پردازش دانشگاه صنعتی امیرکبیر استفاده شد. پایتورچ<sup>۳</sup> یک چارچوب قدرتمند برای یادگیری عمیق است که با استفاده از زبان برنامه‌نویسی پایتون امکانات بسیاری را برای توسعه و آموزش مدل‌های یادگیری عمیق فراهم می‌کند. این چارچوب با داشتن معماری دوسویه اجازه می‌دهد تا عملیات پیچیده‌تری را بر روی شبکه‌های عصبی انجام داده و به‌دقت

1. Cumulative outside global radiation  
 2. Photosynthetically active radiation P  
 3. PyTorch

و کارایی بهتری دست یافته شود و امکان طراحی مدل‌های پیچیده‌تر و تنظیمات متنوع‌تر برای معماری شبکه را ایجاد می‌کند. همچنین، پایتورچ از فناوری پردازش موازی GPU بهره می‌برد که اجرای سریع‌تر و بهینه‌تر الگوریتم‌ها و مدل‌های پیچیده را فراهم می‌کند. با استفاده از قدرت پردازش موازی کارت‌های گرافیکی، می‌توان محاسبات سریع‌تر و بهتری را بر روی داده‌های بزرگ انجام داد و زمان آموزش و استفاده از مدل‌های یادگیری عمیق را بهبود بخشید.

## نتایج و بحث

با توجه به شکل ۴ مشاهده می‌شود که در فرآیند آموزش شبکه پس از انجام ۱۵۰ اپوک انطباق خوبی میان دقت داده‌های آموزش و اعتبارسنجی شبکه صورت گرفته است و در نتیجه شبکه عصبی همگرا شده است؛ بنابراین وزن‌های به دست آمده در اپوک ۱۵۰ به عنوان وزن‌های اصلی شبکه آموزش داده شده ثبت و ذخیره گردید تا به کمک آن بتوان شرایط محیطی گلخانه را با داده‌های ورودی جدید مدل‌سازی نمود.

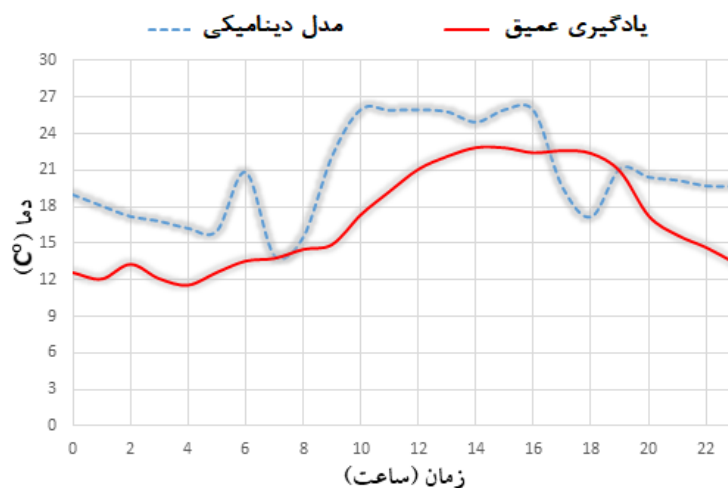


شکل ۴. نمودار روند آموزش شبکه عصبی عمیق در پیش‌بینی آب و هوای داخل گلخانه.

در این مطالعه از یک شبیه‌ساز مبتنی بر شبکه عصبی عمیق برای شرایط محیطی گلخانه استفاده شد که خروجی شبکه نشان از دقت بالای روش پیشنهادی در پیش‌بینی دمای داخل و غلظت دی‌اکسید کربن دارد. دقت پیش‌بینی (ضریب تبیین ( $R^2$ )) مدل شبکه عصبی عمیق برای دمای داخل برابر ۰/۸۱، برای رطوبت نسبی داخل ۰/۶۱ و برای غلظت دی‌اکسید کربن برابر ۰/۸۵ به دست آمد. دمای گلخانه در زمان  $t$  تابعی از شرایط محیط بیرون، شرایط داخلی و اعمال در نظر گرفته شده در زمان  $t-1$  است؛ بنابراین به منظور ایجاد دقت در زمان صفر، تخمین دما در دو روز متوالی صورت گرفته که در عمل روز دوم به عنوان مرجع جهت مقایسه با مدل ریاضی مدنظر قرار بگیرد. توزیع دما در گلخانه به دو روش یادگیری عمیق و کنترل پیش‌بین در شکل ۵ مشاهده می‌گردد.


با توجه به نمودارهای نشان داده شده می‌توان نتیجه گرفت که شبکه عصبی عمیق آموزش داده شده دمای داخل را نسبت به مدل دینامیکی در بازه کمتری کنترل کرده است. این امر در عمل باعث می‌شود که سیاست‌های کنترل دما به نسبت بدبینانه اتخاذ شود و دمای گلخانه در محدوده بالاتری نگه داشته شود؛ بنابراین ممکن است که در مصرف انرژی مدل شبکه عصبی کمی ضعیف‌تر عمل کند. البته این نکته نیز حائز اهمیت که سیاست‌های کنترل گلخانه در مناطق مختلف دنیا با توجه به دسترسی به منابع انرژی متفاوت بوده و با توجه به نوع بذر کشت داخل گلخانه و تحمل دمایی آن ممکن است چنین تغییراتی به وجود بیاید. در یک تحقیق با استفاده از معادلات انتقال حرارت و جرم، یک مدل ریاضی برای تعیین دمای گلخانه در پنج شکل معمولی گلخانه برای شرایط آب و هوایی دهلی، هند انجام شد و میانگین درصد قدر مطلق خطای مدل (MAPE) برابر ۱۱ درصد ارزیابی شد (Singh & Tiwari, 2010). در تحقیقات گذشته نیز شبکه‌های عصبی عملکرد بالایی در پیش‌بینی شرایط داخلی گلخانه از خود نشان داده است. فرامرزی و همکاران میزان تبخیر و تعرق گیاه در گلخانه را بر اساس ماکزیمم و مینیمم دما و سرعت باد با استفاده از شبکه ANN و با دقت  $R = 0/89$  تعیین کردند (Falamarzi et al., 2014). همچنین پیش‌بینی دمای داخل گلخانه بر اساس قوانین فازی در مدل ANFIS با در نظر گرفتن سه متغیر ورودی شامل تابش خورشید،

دمای هوا و رطوبت بیرون گلخانه انجام شد. نتایج نشان داد بهترین روش برای ساخت سامانه استنتاج فازی، روش خوشه‌بندی فازی بهترین تابع عضویت ورودی و خروجی به ترتیب تابع گوسی و خطی است که در این حالت دقت پیش‌بینی دمای داخل گلخانه برابر  $0/۸۶$   $R^2 =$  بود (بلندنظر و همکاران، ۱۳۹۹).



شکل ۵. نمودار توزیع دما در گلخانه به دو روش یادگیری عمیق و کنترل پیش‌بین.

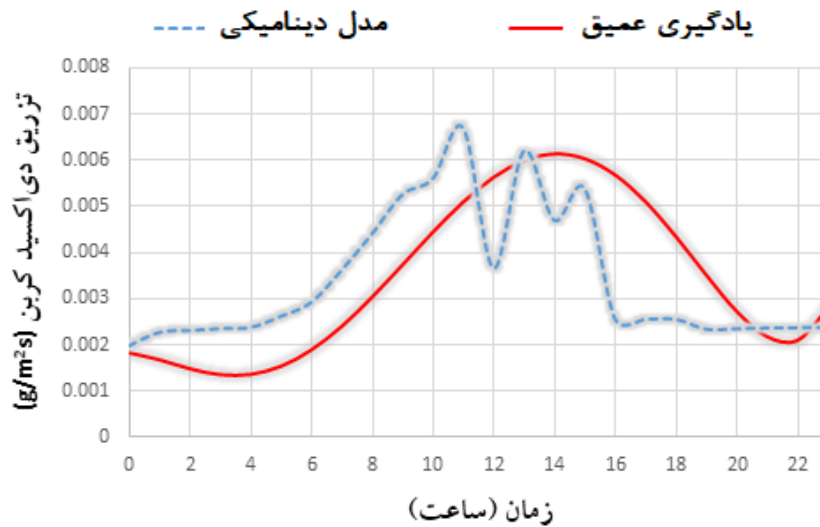
با توجه به نمودار شکل ۶ و توزیع رطوبت نسبی در گلخانه می‌توان دریافت که مدل شبکه عصبی عملکرد متفاوتی از خود نشان داده است و تغییرات رطوبت نسبی در گلخانه تحت کنترل مدل یادگیری عمیق کمتر بوده و در ضمن رطوبت نسبی در محدوده پایین‌تری نگه داشته که برای جلوگیری از رشد قارچ‌ها شرایط مناسب‌تری فراهم می‌آورد.



شکل ۶. نمودار نحوه کنترل رطوبت نسبی در گلخانه به دو روش یادگیری عمیق و کنترل پیش‌بین.


در شکل ۷ میزان تزریق دی‌اکسید کربن در گلخانه به واحد سطح نشان داده شده است. از نظر تطابق نیز، دو نمودار روند کلی یکسانی داشته و می‌توان گفت در طی روز با توجه به دمای بالاتر محیط و در نتیجه نیاز به تهویه بیشتر، نیاز به تزریق دی‌اکسید کربن در راستای نگه داشتن میزان فتوسنتز گیاه در یک سطح مطلوب بالاتر می‌رود. غلظت دی‌اکسید کربن نقش مهمی در تولید گیاه دارد، زیرا یک ماده خام مهم برای فتوسنتز گیاهان است و به طور مستقیم بر رشد و نمو گیاهان تأثیر می‌گذارد. خود فتوسنتز برای جمع‌آوری مواد گیاهی، بهبود کمیت و کیفیت و رشد و نمو آن مهم است. در مطالعه‌ای پیش‌بینی غلظت  $CO_2$  در گلخانه با استفاده از مدل‌های سری زمانی با فواصل ۱، ۵، ۱۰، ۳۰ و ۶۰ دقیقه تبدیل شد. داده‌های سری زمانی با استفاده از میانگین متحرک یکپارچه اتورگرسیون (ARIMA) ارزیابی شد و بهترین عملکرد مدل با داده‌های جمع‌آوری شده در فواصل ۱ دقیقه‌ای به دست آمد، در حالی که عملکرد مدل با فواصل طولانی‌تر کاهش یافت. مدل ARIMA، با داده‌های جمع‌آوری شده در فواصل ۱ دقیقه‌ای دارای دقت به  $R^2 = 0/۹۲$  و در فواصل ۶۰ دقیقه‌ای  $0/۷۶$   $R^2 =$  بود (Shin et al., 2024). در تحقیقی دیگر با استفاده از مدل RNN-LSTM و فاصله زمانی ۳۰ دقیقه غلظت  $CO_2$  با دقت  $0/۸۱$   $R^2 =$  مدل‌سازی شد (Jung et al., 2020). برای پیاده‌سازی سیستم یادگیری عمیق در گلخانه‌های مدرن به منظور کنترل شرایط محیطی

سیستم جمع‌آوری دقیق داده‌های مربوط به دما، رطوبت، نور و سایر پارامترهای محیطی از سنسورها اهمیت بالایی دارد (Chen et al., 2022). پیش‌پردازش داده‌ها به منظور حذف داده پرت و یا نرمال‌سازی قابل استفاده است و برای مدل‌سازی انواع مختلف معماری شبکه بر اساس یادگیری عمیق را باید بررسی کرده و مناسب‌ترین مدل از لحاظ دقت و ثبات انتخاب کرد. از چالش‌های احتمالی این رویکرد استفاده از شبکه عصبی عمیق کیفیت داده‌ها و عملکرد سنسورها است. از سوی دیگر مدل‌های پیچیده ممکن است نیاز به بار محاسباتی زیادی داشته باشند. بر این اساس مدل‌های سبک، پایا و بهینه‌سازی شده و به‌روزرسانی مدل به همراه گرفتن بازخورد مناسب در این سیستم‌ها حیاتی است.



شکل ۷. کنترل میزان تزریق دی‌اکسید کربن در گلخانه به دو روش یادگیری عمیق و کنترل پیش‌بین.

تطابق تنظیم دمای گلخانه با شبکه عمیق با مقدار حقیقی اهمیت بالایی دارد. شکل ۸ درک بهتری از تطابق مقدار پیش‌بینی و دمای واقعی گلخانه در زمان متناظر را نشان می‌دهد.



شکل ۸. مقایسه دمای پیش‌بینی و دمای گلخانه.

مدل‌های هوش مصنوعی می‌توانند حجم وسیعی از داده‌ها را تجزیه و تحلیل کنند و الگوهای پیچیده‌ای را شناسایی کنند که ممکن است به راحتی با مدل دینامیکی قابل تشخیص نباشند. این امر منجر به پیش‌بینی دقیق شرایط داخل گلخانه می‌شود و به بهینه‌سازی شرایط محیطی برای رشد گیاه کمک می‌کند (Jia & Wei, 2022). مدل‌های هوش مصنوعی توانایی انطباق و یادگیری از داده‌های جدید را دارند که به آن‌ها امکان می‌دهد به‌طور مداوم قابلیت‌های پیش‌بینی خود را در طول زمان بهبود بخشند. پیش‌بینی پویاتر و پاسخگوتر منجر به تصمیم‌گیری بهتر برای مدیریت گلخانه می‌شود. همچنین نظارت بر شرایط محیطی در گلخانه‌ها در زمان واقعی فراهم‌شده و در صورت

نیاز امکان تنظیم فوری را در حلقه بازخورد بلادرنگ فراهم می‌کند.

در نهایت مدل‌های هوش مصنوعی می‌توانند تجزیه و تحلیل جامع چندین متغیر را به‌طور هم‌زمان با در نظر گرفتن عواملی مانند دما، رطوبت، سطوح نور و غلظت دی‌اکسید کربن در کنار کاهش هزینه و افزایش عملکرد به‌صورت کلی انجام دهند. این رویکرد یکپارچه درک کامل‌تری از فعل و انفعالات پیچیده را فراهم می‌کند که منجر به پیش‌بینی‌های مناسب و استراتژی‌های مؤثرتر در مدیریت می‌شود. مقایسه کلی یادگیری عمیق با روش مبتنی بر مدل دینامیکی مورد ارزیابی قرار گرفت که نتایج آن در جدول ۲ به شکل خلاصه ارائه شده است. ایجاد گلخانه‌های هوشمند نقش مهمی در هموار کردن راه به‌سوی کشاورزی دقیق ایفا می‌کند. چنین گلخانه‌هایی شامل دستگاه‌های پشتیبانی تصمیم هستند که از الگوریتم‌های پیش‌بینی پیچیده برای پیش‌بینی طیف گسترده‌ای از پارامترها استفاده می‌کنند (Morales-García et al., 2024). نتایج این تحقیق با تأیید تحقیقات دیگر نشان داده که مدل‌های یادگیری عمیق چندگانه که به‌طور هم‌زمان برای پیش‌بینی مجموعه‌ای از پارامترهای محیطی گلخانه استفاده می‌شوند دارای قابلیت بالایی برای کنترل گلخانه و اجرای سناریوهای مختلف با لحاظ کردن عوامل عملکرد و هزینه‌ها هستند.

جدول ۲. ویژگی‌ها و مزایای مدل یادگیری عمیق نسبت به کنترل پیش‌بین.

کنترل پیش‌بین	یادگیری عمیق
نیازمند مدل دینامیکی خوب	امکان به‌کارگیری بدون استفاده از مدل قبلی
بهینه‌سازی از یک مدل محدب درجه دوم <sup>۱</sup>	آموزش به‌منظور تصمیم‌گیری
عملکرد ضعیف در پیش‌بینی‌های بلندمدت	تصمیم‌گیری پیوسته و بلندمدت
بار محاسباتی بالا به‌منظور حذف عدم قطعیت‌ها	پایداری ذاتی بالا
سازگاری کم	سازگاری بالا
پیچیدگی‌های بالا در بهینه‌سازی بلادرنگ	پیچیدگی‌های کم در آموزش بلادرنگ

## نتیجه‌گیری

در این تحقیق به‌منظور کنترل گلخانه یک روش یادگیری عمیق طراحی شد و نتایج آن با روش مبتنی بر مدل مورد مقایسه قرار گرفت. این مقایسه با هدف مشاهده و بررسی رویکرد هر دو روش کنترلی در پیش‌بینی واقع‌گرایانه متغیرهای محیطی برای محصول گوجه‌فرنگی در گلخانه شیشه‌ای انجام شد. عملکرد خوب مدل شبکه عصبی عمیق به دلیل استفاده از داده‌های عملیاتی گلخانه تحت کنترل کارشناسان خبره در کنار قابلیت تشخیص الگو در مدل بود. البته وجود مدل‌های دینامیکی نیز در جایگاه ارزشمندی بوده و در زمان نبود کارشناسان خبره به‌منظور راه‌اندازی گلخانه در یک نقطه جغرافیایی جدید می‌تواند ارزشمند باشد. در تحقیقات آینده پیشنهاد می‌شود از سایر مدل‌های یادگیری عمیق به همراه بهینه‌سازی ساختار آن برای کاهش هزینه تولید و بهینه‌سازی مصرف انرژی با استفاده از داده‌های نقاط جغرافیایی مختلف استفاده گردد.

## منابع

بلندنظر، الهام، صدرنیا، حسن، روحانی، عباس و تاکی، مرتضی. (۱۳۹۹). پیش‌بینی دمای هوای یک گلخانه با پوشش پلی اتیلن با استفاده از شبکه‌های عصبی مصنوعی، مطالعه موردی: منطقه جیرفت. مهندسی بیوسیستم ایران، ۵۱(۱)، ۱۳۷-۱۲۵.  
مرکز آمار ایران، (۱۳۹۹). سالنامه آماری کشور. کشاورزی، جنگلداری و شیلات.

## REFERENCES

- Ajagekar, A., & You, F. (2022). Deep reinforcement learning based automatic control in semi-closed greenhouse systems. *IFAC-PapersOnLine*, 55(7), 406–411. <https://doi.org/10.1016/j.ifacol.2022.07.477>
- Bolandnazar, E., sadrnia, hassan, Rohani, A., & Taki, M. (2020). Prediction of Temperature in a Greenhouse Covered with Polyethylene Plastic Using Artificial Neural Networks, Case Study: Jiroft Region. *Iranian Journal of Biosystems Engineering*, 51(1), 125–137. (In Persian). <https://doi.org/10.22059/ijbse.2019.291077.665235>
- Bot, G. P. A. (1991). Physical modeling of greenhouse climate. *IFAC Proceedings Volumes*, 24(11), 7–12.





<https://doi.org/10.1016/B978-0-08-041273-3.50006-9>

- Chalabi, Z. S., & Bailey, B. J. (1991). Sensitivity analysis of a non-steady state model of the greenhouse microclimate. *Agricultural and Forest Meteorology*, 56(1–2), 111–127. [https://doi.org/10.1016/0168-1923\(91\)90107-2](https://doi.org/10.1016/0168-1923(91)90107-2)
- Chen, T.-H., Lee, M.-H., Hsia, I.-W., Hsu, C.-H., Yao, M.-H., & Chang, F.-J. (2022). Develop a smart microclimate control system for greenhouses through system dynamics and machine learning techniques. *Water*, 14(23), 3941.
- De Zwart, H. F. (1996). Analyzing energy-saving options in greenhouse cultivation using a simulation model. Wageningen University and Research.
- Falamarzi, Y., Palizdan, N., Huang, Y. F., & Lee, T. S. (2014). Estimating evapotranspiration from temperature and wind speed data using artificial and wavelet neural networks (WNNs). *Agricultural Water Management*, 140, 26–36. <https://doi.org/10.1016/j.agwat.2014.03.014>
- Ferreira, P. M., Faria, E. A., & Ruano, A. E. (2002). Neural network models in greenhouse air temperature prediction. *Neurocomputing*, 43(1–4), 51–75. [https://doi.org/10.1016/S0925-2312\(01\)00620-8](https://doi.org/10.1016/S0925-2312(01)00620-8)
- Gong, L., Yu, M., Jiang, S., Cutsuridis, V., & Pearson, S. (2021). Deep learning based prediction on greenhouse crop yield combined TCN and RNN. *Sensors*, 21(13), 4537. <https://doi.org/10.3390/s21134537>
- He, G., Geng, C., Zhai, J., Zhao, Y., Wang, Q., Jiang, S., Zhu, Y., & Wang, L. (2021). Impact of food consumption patterns change on agricultural water requirements: An urban-rural comparison in China. *Agricultural Water Management*, 243, 106504. <https://doi.org/10.1016/j.agwat.2020.106504>
- He, L., Du, Y., Wu, S., & Zhang, Z. (2021). Evaluation of the agricultural water resource carrying capacity and optimization of a planting-raising structure. *Agricultural Water Management*, 243, 106456. <https://doi.org/10.1016/j.agwat.2020.106456>
- Hemming, S., de Zwart, F., Elings, A., Righini, I., & Petropoulou, A. (2019). Remote control of greenhouse vegetable production with artificial intelligence—greenhouse climate, irrigation, and crop production. *Sensors*, 19(8), 1807. <https://doi.org/10.3390/s19081807>
- Hemming, S., Zwart, F. de, Elings, A., Petropoulou, A., & Righini, I. (2020). Cherry tomato production in intelligent greenhouses—Sensors and AI for control of climate, irrigation, crop yield, and quality. *Sensors*, 20(22), 6430. <https://doi.org/10.3390/s20226430>
- Heuvelink, E. (1996). Tomato growth and yield: quantitative analysis and synthesis. Wageningen University and Research.
- Hu, H.-G., Xu, L.-H., Wei, R.-H., & Zhu, B.-K. (2011). RBF network based nonlinear model reference adaptive PD controller design for greenhouse climate. *Int. J. Adv. Comput. Technol*, 3, 357–366.
- Jia, W., & Wei, Z. (2022). Short term prediction model of environmental parameters in typical solar greenhouse based on deep learning neural network. *Applied Sciences*, 12(24), 12529.
- Jung, D.-H., Kim, H. S., Jhin, C., Kim, H.-J., & Park, S. H. (2020). Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. *Computers and Electronics in Agriculture*, 173, 105402.
- Klarin, B., Garafulić, E., Vučetić, N., & Jakšić, T. (2019). New and smart approach to aeroponic and seafood production. *Journal of Cleaner Production*, 239, 117665. <https://doi.org/10.1016/j.jclepro.2019.117665>
- Konig, B., Kuntosch, A., Bokelmann, W., Doernberg, A., Schwerdtner, W., Busse, M., Siebert, R., Koschatzky, K., & Stahlecker, T. (2012). *Analysing agricultural innovation systems: a multilevel mixed methods approach*. <https://doi.org/10.22004/ag.econ.135792>
- Lin, D., Zhang, L., & Xia, X. (2021). Model predictive control of a Venlo-type greenhouse system considering electrical energy, water and carbon dioxide consumption. *Applied Energy*, 298(October 2020), 117163. <https://doi.org/10.1016/j.apenergy.2021.117163>
- McNulty, J. (2017). Solar greenhouses generate electricity and grow crops at the same time, UC Santa Cruz study reveals. In *USC Newscenter*. University of California.
- Morales-García, J., Terroso-Sáenz, F., & Cecilia, J. M. (2024). A multi-model deep learning approach to address prediction imbalances in smart greenhouses. *Computers and Electronics in Agriculture*, 216, 108537.
- Seginer, I. (1997). Some artificial neural network applications to greenhouse environmental control. *Computers and Electronics in Agriculture*, 18(2–3), 167–186. [https://doi.org/10.1016/S0168-1699\(97\)00028-8](https://doi.org/10.1016/S0168-1699(97)00028-8)
- Seginer, I., Boulard, T. H., & Bailey, B. J. (1994). Neural network models of the greenhouse climate. *Journal of Agricultural Engineering Research*, 59(3), 203–216. <https://doi.org/10.1006/jaer.1994.1078>

- Shi, D., Yuan, P., Liang, L., Gao, L., Li, M., & Diao, M. (2024). Integration of deep learning and sparrow search algorithms to optimize greenhouse microclimate prediction for seedling environment suitability. *Agronomy*, *14*(2), 254.
- Shin, S. H., Deb, N. C., Arulmozhi, E., Tamrakar, N., Ogundele, O. M., Kook, J., Kim, D. H., & Kim, H. T. (2024). Prediction of Carbon Dioxide Concentrations in Strawberry Greenhouse by Using Time Series Models. *Agriculture*, *14*(11), 1895. <https://doi.org/10.3390/agriculture14111895>
- Singh, R. D., & Tiwari, G. N. (2010). Energy conservation in the greenhouse system: A steady state analysis. *Energy*, *35*(6), 2367–2373. <https://doi.org/10.1016/j.energy.2010.02.003>
- Statistical Center of Iran, (2019). National Statistical Yearbook. Agriculture, Forestry and Fisheries. (In Persian).
- Van Henten, E. J. (2003). Sensitivity Analysis of an Optimal Control Problem in Greenhouse Climate Management. *Biosystems Engineering*, *85*(3), 355–364. [https://doi.org/https://doi.org/10.1016/S1537-5110\(03\)00068-0](https://doi.org/https://doi.org/10.1016/S1537-5110(03)00068-0)
- Vanthoor, B. H. E. (2011). *A model-based greenhouse design method*. Wageningen University and Research.
- Vanthoor, B. H. E., De Visser, P. H. B., Stanghellini, C., & Van Henten, E. J. (2011). A methodology for model-based greenhouse design: Part 2, description and validation of a tomato yield model. *Biosystems Engineering*, *110*(4), 378–395. <https://doi.org/10.1016/j.biosystemseng.2011.08.005>
- Vanthoor, B. H. E., Stanghellini, C., Van Henten, E. J., & De Visser, P. H. B. (2011). A methodology for model-based greenhouse design: Part 1, a greenhouse climate model for a broad range of designs and climates. *Biosystems Engineering*, *110*(4), 363–377. <https://doi.org/10.1016/j.biosystemseng.2011.06.001>
- Wang, D., Wang, M., & Qiao, X. (2009). Support vector machines regression and modeling of greenhouse environment. *Computers and Electronics in Agriculture*, *66*(1), 46–52. <https://doi.org/10.1016/j.compag.2008.12.004>
- Zeng, S., Hu, H., Xu, L., & Li, G. (2012). Nonlinear adaptive PID control for greenhouse environment based on RBF network. *Sensors*, *12*(5), 5328–5348. <https://doi.org/10.3390/s120505328>