

Development of a Soft Sensor Based on Supervised Feature Selection for Temperature Monitoring of Fruit Pallets in Cold Storage

Sayed Matin Mortazavi ¹, Saeid Minaee ^{2*}, Alireze Mahdavian ³,
Mohammad Hadi Khoshtaghaza ⁴

¹ PHD student, Department of Mechanical Engineering of Biosystems, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran.

² Prof, Department of Mechanical Engineering of Biosystems, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran.

³ Assoc. Prof., Department of Mechanical Engineering of Biosystems, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran.

⁴ Prof, Department of Mechanical Engineering of Biosystems, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran.

Article information

Received: 2024/12/28

Accepted: 2025/05/01

Keywords:

Arduino
Temperature
Estimation Methods
Cold chain
Time-Delay Neural
Networks

*Corresponding author:

minaee@modares.ac.ir

ORCID: 

0000-0003-2241-5621



Extended Abstract

Introduction

Temperature is a critical factor affecting the quality and shelf life of perishable food products, making the precise and cost-effective monitoring of its levels essential throughout the cold chain. Due to practical limitations in deploying physical sensors at every point of interest, the development of soft (virtual) sensors for temperature estimation has attracted considerable research attention. Soft sensors are generally categorised into model-based and data-driven approaches, with the latter offering superior capability in capturing system dynamics without requiring detailed physical modelling. Among various data-driven methods, artificial neural networks (ANNs) have demonstrated superior performance compared to alternative techniques.

The first step in designing a data-driven soft sensor is to collect and prepare training data, which can be either experimental or synthetic. Studies indicate that experimental data lead to more accurate estimations, although they are harder to obtain. A crucial subsequent step involves selecting appropriate input variables corresponding to potential sensor locations. While most previous studies have relied on subjective or heuristic input selection, supervised feature selection methods offer a structured and potentially more optimal

alternative; however, such methods have rarely been applied in the context of temperature soft sensors for cold chains.

Once inputs and outputs are defined, the modelling process typically employs ANNs, which have shown superior estimation performance over classical models. The present study implements supervised feature selection to optimise both the number and placement of physical sensors and to statistically investigate the effects of key hyperparameters in the time-delay neural network (TDNN) serving as the system's soft sensor estimator.

Method

A cost-effective, Arduino-based data logger was developed to collect real temperature data for training the soft sensor. Temperature distribution data were collected from two peach pallets stored in a 2000-ton cold storage room maintained at 1 °C. The logger simultaneously recorded data from up to 20 DS18B20 sensors at 1-minute intervals. A novel supervised feature selection approach (wrapper method) was applied to identify the most informative sensor positions, thereby minimizing the required number of physical sensors. A time-delay neural network (TDNN) with one hidden layer was employed for temperature estimation. The influence of four key hyperparameters—time delay, number of hidden neurons, activation function, and training algorithm—on model performance metrics (RMSE, R^2 , MAE, BIC) was evaluated. Additionally, a metaheuristic algorithm was used to assess the effectiveness of the feature selection method in reducing the sensor count. Model generalisability was verified using an out-of-sample test set collected under varying temperature scenarios and pallet placements.

Results

Data acquisition for the first pallet lasted five hours, during which the cold storage refrigeration system operated under standard conditions. Table 1 ranks the five most informative sensor locations identified using the FIRE method. Table 3 presents the best model fits obtained with the SIG and ReLU activation functions. These models share a common structure: Levenberg–Marquardt (LM) training and a 20-minute time delay. Comparing activation functions reveals that ReLU yields superior performance metrics (R^2 mean and RMSEmean), while SIG achieves a lower BIC. Figure 4 illustrates how R^2 mean and RMSEmean vary as the number of physical sensors is reduced based on FIRE rankings under the optimal estimator configuration (LM2010-ReLU), showing no consistent trend and indicating the robustness of FIRE's variable selection. For the second pallet, data acquisition also spanned five hours; however, the refrigeration system was inactive for defrosting during the first three hours and resumed operation in the final two. Table 2 shows the FIRE-derived variable ranking, and Table 4 lists the best model fits for this dataset. All models for the second pallet employed LM training, a 20-minute delay, and five hidden neurons. In this case, performance metrics (R^2 mean and RMSEmean) progressively deteriorated as the number of sensors used decreased (Figure 4), indicating a greater sensitivity to sensor reduction under dynamic thermal conditions.

Correlation analysis revealed strong relationships between RMSEmean and MAEmean, as well as among MSEtrain, MSEvalidation, and MSEtest; however, R^2 mean showed little correlation with these variables. BIC exhibited a significant correlation with several metrics. Consequently, MSEtrain, R^2 mean, and RMSEmean were deemed sufficient for performance evaluation.

The influence of estimator hyperparameters (Table 5) indicated that the training method significantly affected performance, favouring LM. Hidden layer size and time delay primarily influenced BIC, while activation function showed no significant effect, consistent with Loisel et al. (2022). Ant Colony Optimisation (ACO) was applied to validate FIRE rankings (Figure 5). ACO results revealed alternative sensor combinations yielding lower RMSEmean than FIRE, suggesting that heuristic methods may offer superior configurations for "one-sensor-per-

pallet" setups. Table 6 compares FIRE and ACO outcomes, confirming ACO's advantage in reducing the mean RMSE.

Cross-pallet validation demonstrated that the soft sensor trained on one pallet and tested on the other under different thermal scenarios achieved RMSE_{mean} values of 0.8 K and 1.0 K—13–15 times higher than the training RMSE_{mean}, but acceptable given the scenario differences. However, R^2_{mean} (~0.4) indicated limited generalisation, implying that future training with diverse scenarios would enhance robustness (Figure 6).

Conclusions

The findings of this study demonstrate the high potential of supervised feature selection as a structured and objective method for identifying the most informative locations for hardware sensor placement in the development of soft sensors. However, to further reduce the required number of hardware sensors, the use of alternative methods, such as metaheuristic algorithms or exhaustive search techniques, appears to be a more prudent approach. In this regard, future research could explore and compare different supervised feature selection techniques to assess their ranking effectiveness and robustness in similar applications.

The out-of-sample evaluation of the developed soft sensor in the "one-pallet-one-sensor" configuration yielded RMSE mean values ranging between 0.8 K and 1.0 K. This outcome is considered acceptable given the "single-scenario training" condition. Nevertheless, several factors could influence the accuracy and generalisation performance of the soft sensor, including: (1) the size of the dataset (in terms of duration or number of data points), (2) the temperature scenario or the operational state of the refrigeration system, and (3) the location of the pallets within the cold storage. Therefore, increasing the diversity of data acquisition conditions—such as varying spatial placement or thermal scenarios—is likely to yield valuable information for further improving the soft sensor's performance and predictive accuracy.

Author Contributions

Matin Mortazavi: Conceptualization, Data curation, Formal analysis, Investigation, Software, Visualization, Writing – original draft.

Saeid Minaei: Methodology, Resources, Project administration, Funding acquisition, Writing – review and editing

Alireza Mahdavian: Methodology, Validation, Supervision.

Mohamad-Hadi Khosh-Taghaza: Resources, Writing – review and editing.

Data Availability Statement

The datasets analysed during this study are not publicly available due to confidentiality agreements but can be provided to qualified parties upon request from the corresponding author and approval of the department.

Acknowledgements

The authors express their gratitude to Tarbiat Modares University for providing financial, laboratory, and technical support (Research Grant No. 9730912003).

Ethical Considerations

Authors proclaim that ethical considerations have been observed in conducting this study and confirm adherence to ethical standards, including avoidance of data fabrication, falsification, plagiarism, and misconduct.

Conflict of Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper

Funding Statement

The author(s) received no specific funding for this research

How to cite this paper:

Mortazavi, M., Minaei, S., Mahdavian, A., and Khosh-Taghaza, M. H. (2025). Journal of Researches in Mechanics of Agricultural Machinery. 35: 83-101.
<https://dx.doi.org/10.22034/jrmam.2025.15032.739>



Authors retain the copyright and full publishing rights.
Published by [Shahrekord University](#). This article is an open access article licensed under the [Creative Commons Attribution 4.0 International \(CC BY 4.0\)](#)



توسعه حسگر نرم برای پایش دمای پالت‌های سردخانه میوه با به کارگیری انتخاب ویژگی نظارت‌شده

سیدمتین مرتضوی^۱، سعید مینایی^{۲*}، علیرضا مهدویان^۳، محمدهادی خوش تقاضا^۴

۱- دانشجوی دکتری، گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران

۲- استاد، گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران

۳- استادیار، گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران

۴- استاد، گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران

چکیده

اطلاعات مقاله

تغییرات کاربری اراضی کشاورزی در اثر عوامل انسانی یا طبیعی و پایش آن یکی از مهم‌ترین چالش‌ها در استان‌های شمالی کشور است. الگوریتم‌های مختلف یادگیری ماشین برای مناطق با ویژگی‌های خاص مکانی دارای عملکردهای متفاوتی هستند. هدف از مطالعه حاضر، استفاده از تصویر ماهواره‌ای سنتینل-۲ جهت طبقه‌بندی کاربری اراضی شهرستان ماسال و مقایسه‌ی طبقه‌بندی‌های بیشینه احتمال، حداقل فاصله، فاصله ماهالانویس و ماشین بردار پشتیبان با هسته‌های خطی، چندجمله‌ای، سیگموئید و توابع پایه شعاعی است. برای فراهم آوردن داده‌های تعلیمی و آزمون برای الگوریتم‌ها، علاوه بر نقاط برداشت زمینی توسط سیستم موقعیت‌یاب جهانی و نقشه‌های Google Earth، از شاخص‌های طیفی شامل شاخص سبزی تفاضلی نرمال شده، شاخص تفاضلی نرمال شده سازه‌ها و شاخص آب تفاضلی نرمال شده سازه‌ها نیز برای تعیین دقیق‌تر واقعیت‌های زمینی استفاده شد. اعتبارسنجی مدل‌ها توسط ماتریس اغتشاش و محاسبه‌ی عامل‌های ضریب کاپا و صحت کل انجام شد. نتایج نشان داد الگوریتم بیشینه احتمال با صحت کلی و ضریب کاپا به ترتیب ۹۷/۲۹ درصد و ۰/۹۶ دقیق‌ترین عملکرد طبقه‌بندی را به خود اختصاص داده و الگوریتم ماشین بردار پشتیبان با هسته خطی با مقادیر ضریب کاپا و صحت کلی به ترتیب ۹۲/۴۶ درصد و ۰/۸۹ در رتبه بعدی قرار داشت. ضعیف‌ترین عملکرد به الگوریتم حداقل فاصله با صحت کل ۷۲/۹۷ درصد و ضریب کاپای ۰/۶۶ تعلق داشت. با توجه به نتایج این تحقیق، طبقه‌بند بیشینه احتمال، عملکرد بهتری را در تفکیک کاربری‌های اراضی شهرستان ماسال ارائه داده است. نتایج این تحقیق برای سیاست‌گذاران و مدیران استان در آگاهی از تغییرات کاربری زمین‌های کشاورزی و جنگلی منطقه حائز اهمیت است.

تاریخ دریافت: ۱۴۰۳/۱۰/۰۸

تاریخ پذیرش: ۱۴۰۴/۰۲/۱۱

واژه‌های کلیدی:

آردوینو

روش‌های برآورد دما

زنجیره سرد

شبکه عصبی با تأخیر زمانی

فساد مواد خوراکی

*پست الکترونیکی نویسنده

مسئول:

minace@modares.ac.ir

ORCID: 

۰۰۰۰-۰۰۰۳-۲۲۴۱-۵۶۲۱



مقدمه

دما مهم‌ترین عامل تأثیرگذار بر کیفیت مواد خوراکی فاسدشدنی است که برای اکثر آن‌ها، مستقیماً روی ماندگاری محصول تأثیر می‌گذارد (Lim et al., 2022; Mercier & Uysal, 2018). به همین علت، پایش دما با وضوح مکانی بالا و به‌شکلی کم‌هزینه، در تمام مسیر زنجیره سرد (اعم از انبارمانی و حمل‌ونقل)، مهم و ارزشمند است (Gillespie et al., 2023; Maruthi et al., 2023; Zou et al., 2023). پژوهش‌های متعددی، روش‌های تخمین دما را برای غلبه بر محدودیت‌های حسگرهای سخت‌افزاری^۱ در افزایش وضوح مکانی اندازه‌گیری‌ها انتخاب کردند (Loisel et al., 2021). در تمامی این پژوهش‌ها؛ هدف توسعه یک الگوریتم تخمین‌گر است که امکان برآورد دما را در نقاطی که نصب حسگر سخت‌افزاری در آنها محدودیت دارد، فراهم کند. در مرور منابع، این تخمین‌گر را حسگر نرم^۲ یا حسگر مجازی^۳ نامیده‌اند (Stavropoulos et al., 2023; Brunello et al., 2021).

روش‌های مدل‌سازی حسگرهای نرم به دو دسته طبقه‌بندی می‌شوند: ۱- مبتنی بر مدل و ۲- داده-محور (Perera et al., 2023; Xu et al., 2022; Curreri et al., 2020). مزیت حسگرهای نرم داده-محور آن است که بدون نیاز به درک ارتباط فیزیکی بین متغیرهای مختلف، قابلیت مدل‌سازی دقیق رفتار پویای سیستم را پیدا می‌کنند. لذا می‌توانند بدون درگیر شدن با یک مدل پیچیده ریاضیاتی (که بتواند تمام یا لاکل اکثر عامل‌های تأثیرگذار روی تغییرات دما را در نظر بگیرد)، عملکرد تخمینی بالاتری در مقایسه با حسگرهای نرم مبتنی بر مدل داشته باشند (Hoang et al., Perera et al., 2023; Lim et al., 2022; 2021). در بین انواع روش‌های مورد مطالعه برای توسعه حسگر نرم داده‌محور؛ عملکرد الگوریتم‌های یادگیری ماشین و به‌طور خاص؛ شبکه‌های عصبی مصنوعی، بهتر از سایر روش‌ها (مانند روش خازنی و کریجینگ) بوده است (Badia-Melis et al., 2018) و نتایج به دست آمده از شبکه‌های عصبی مصنوعی، بهترین حالتی است که می‌توان از به کارگیری الگوریتم‌های

یادگیری ماشین در این حوزه، انتظار داشت (Loisel et al., 2022; Swain & Jenamani, 2022).

نخستین گام در طراحی یک حسگر نرم داده‌محور جمع‌آوری و آماده‌سازی داده‌های موردنیاز برای آموزش الگوریتم تخمین‌گر است. (Loisel et al., 2022). دو نوع منبع داده را برای آموزش یک شبکه عصبی مصنوعی بررسی کردند: ۱- داده‌های تجربی (که آن را به‌صورت آزمایشگاهی جمع‌آوری کرده بودند) و ۲- داده‌های مصنوعی (که با به کارگیری مدل‌های حرارتی و شبیه‌سازی، تولید شده بودند). نتایج پژوهش آنها نشان داد؛ عملکرد مدلی که با داده‌های تجربی آموزش دیدند بهتر، و RMSE آنها کم‌تر بوده است، و تنها چالش در به کارگیری داده‌های تجربی؛ محدودیت‌ها و سختی‌های به دست آوردن این نوع منبع داده است. آنها هم-چنین به این نکته اشاره کردند که به‌منظور توسعه یک سامانه حسگر نرم برای سنجش دما در زنجیره سرد، ضروری نیست یک مطالعه میدانی کامل برای شناسایی سناریوی‌های دمایی معرف آن زنجیره سرد، انجام شود.

پس از جمع‌آوری و آماده‌سازی داده‌ها، مهم‌ترین مسأله انتخاب متغیرهای ورودی است (Curreri et al., 2020). وقتی صحبت از تخمین دما در یک محیط مشخص (برای نمونه: پالت‌های میوه) باشد؛ متغیرهای ورودی در واقع آن موقعیت‌هایی هستند که قرار است حسگرهای سخت‌افزاری در آن‌ها نصب شود. به طور کلی؛ در رویکرد مدل‌سازی داده‌محور، پیش‌فرضی درباره موقعیت نصب حسگر(های) سخت‌افزاری وجود ندارد که بتواند ساختار مدل را تحت تأثیر قرار دهد (May et al., 2011)؛ لذا طراح حسگر نرم باید داده‌های جمع‌آوری شده را با روش‌های مختلف آزمون کند تا آن متغیرهایی را که دارای اطلاعات مفید و غیرتکراری هستند، به‌عنوان ورودی شناسایی کند (Curreri et al., 2020; May et al., 2011). با این وجود؛ انتخاب ورودی‌ها در اکثر پژوهش‌های مرتبط، به‌صورت سلیقه‌ای/ داوطلبانه انجام شده است. برای نخستین بار (Mercier & Uysal, 2018) یک روش ساختارمند و غیرسلیقه‌ای را به کار گرفتند و انتخاب موقعیت‌های مناسب برای نصب حسگرهای سخت‌افزاری را با

³ Virtual Sensor

¹ Hardware Sensor

² Soft Sensor

تغییر معماری، تأثیر محسوسی بر عملکرد مدل تخمین‌گر ندارد.

با توجه به مرور منابع انجام‌گرفته؛ پژوهشی که در آن به‌منظور توسعه حسگر نرم برای سنجش دمای زنجیره سرد، از روش‌های نظارت‌شده انتخاب ویژگی برای انتخاب موقعیت و تعداد بهینه حسگرهای سخت‌افزاری استفاده شده باشد، یافت نشد. این در حالی است که این روش‌ها علاوه بر ارائه یک راه‌حل ساختارمند و غیرسلیقه‌ای، می‌توانند به رتبه‌بندی متغیرهای انتخابی نیز بپردازند که ممکن است بتوان از آن برای کاهش تعداد حسگرهای سخت‌افزاری مورد نیاز بهره برد. لذا هدف اصلی پژوهش حاضر؛ به کارگیری قابلیت انتخاب ویژگی نظارت‌شده در تعیین موقعیت نصب حسگرهای سخت‌افزاری و کاهش تعداد آن‌ها است. علاوه بر این؛ تأثیر فراعامل‌های مهم «شبکه عصبی با تأخیر زمانی»^۸ (به‌عنوان الگوریتم تخمین‌گر سامانه حسگر نرم) بر دقت برآوردهای آن، به‌شکل آماری مورد بررسی قرار گرفته است.

مواد و روش‌ها

ابتدا یک داده‌نگار مقرون به صرفه (بر پایه آردوینو) برای ثبت مقادیر دما ساخته شد تا «یک مجموعه داده واقعی»^۹ برای آموزش حسگر نرم فراهم‌گردد. در مرحله بعد؛ عملکرد یکی از روش‌های نظارت‌شده انتخاب ویژگی (از رویکرد «بسته‌بندها») در تعیین موقعیت نصب حسگرهای سخت‌افزاری، مورد بررسی قرار گرفته و از رتبه‌بندی حاصل از آن برای کاهش تعداد حسگرهای سخت‌افزاری مورد نیاز، استفاده شد. شایان اشاره است؛ یک «شبکه عصبی با تأخیر زمانی» به‌عنوان الگوریتم تخمین‌گر حسگر نرم انتخاب شد و تأثیر چهار فراعامل^{۱۰} اصلی آن (شامل: ۱- اندازه تأخیر زمانی، ۲- تعداد نرون‌های لایه پنهان، ۳- تابع فعال‌ساز لایه پنهان و ۴- روش آموزش شبکه عصبی) بر سنج‌های عملکرد، مورد مطالعه قرار گرفتند. هم‌چنین؛ قابلیت روش انتخاب ویژگی اعمال‌شده در کاهش تعداد حسگرهای سخت‌افزاری مورد نیاز، با به کارگیری یک الگوریتم

استفاده از مفهوم هم‌خطی^۱ انجام دادند. آنها سه نقطه در درون پالتی به ابعاد ۸۰×۱۲۰ و ارتفاع ۵۰ سانتی‌متر را که هم‌خطی پایینی با یکدیگر داشتند، به عنوان نقاط ورودی الگوریتم تخمین‌گر خود انتخاب کردند. انواع روش‌های نظارت‌شده انتخاب ویژگی (فیلتر^۲، بسته‌بند^۳ و توکار^۴) را نیز می‌توان برای حل مسأله انتخاب متغیرهای ورودی بکار برد (Curreiri et al., 2020; Souza et al., 2016; May et al., 2011) اگرچه منبعی مرتبط با توسعه حسگر نرم برای سنجش دما در زنجیره سرد، که از این روش‌ها بهره‌برده باشد، یافت نشد.

با مشخص‌شدن ورودی‌ها و خروجی‌های الگوریتم تخمین‌گر؛ فرآیند توسعه وارد فاز مدل‌سازی می‌شود. پژوهش‌ها حاکی از عملکرد بهتر شبکه‌های عصبی مصنوعی (نسبت به مدل‌های خطی، ماشین‌بردار پشتیبان و جنگل تصادفی) در استفاده به‌عنوان تخمین‌گر حسگر نرم برای سنجش دما هستند (Loisel et al., 2022) بر اساس مرور منابع انجام‌شده؛ نخستین به کارگیری شبکه‌های عصبی برای تخمین دمای درون پالت با استفاده از سری‌های زمانی چندمتغیره، توسط Nascimento Nunes et al. (2014) انجام شده‌است. آنها از یک شبکه عصبی کاملاً-متصل^۵ برای تخمین دمای درون پالت با استفاده از حسگرهای نصب‌شده در بیرون پالت، استفاده، و کاربرد شبکه عصبی مصنوعی در تخمین دما را نویدبخش توصیف کردند. Mercier & Uysal (2018) تأثیر فراعامل‌های تأخیر زمانی و اندازه لایه پنهان بر عملکرد شبکه عصبی مصنوعی را، در شرایطی که از روش آموزش مارکوآرت-لونبرگ^۶ برای آموزش آن استفاده شود، بررسی کردند. نتایج پژوهش آنها نشان داد که اندازه لایه پنهان از تأخیر زمانی تأثیر می‌پذیرد و افزایش تأخیر زمانی از ۱۰ به ۲۰ دقیقه می‌تواند دقت تخمین‌ها را بهبود بخشد. (Loisel et al., 2022) نیز تأثیر معمارهای مختلف لایه پنهان را با در نظر گرفتن تأخیر زمانی ۵۰ دقیقه و تابع فعال‌سازی «واحد یک‌سو شده خطی»^۷ (برای لایه پنهان) بررسی کردند و نتیجه گرفتند که

^۶ Marquardt-Levenberg

^۷ Rectified Linear Unit (ReLU)

^۸ Time-Delay Neural Network (TDNN)

^۹ Real-World Dataset

^{۱۰} Hyper-Parameter

^۱ Collinearity

^۲ Filter

^۳ Wrapper

^۴ Embedded

^۵ Fully-Connected

برای مدار آردینو به صورت آدرس‌پذیر قابل شناسایی است؛ لذا تعداد زیادی از این حسگرها را می‌توان به یک خط داده مدار آردینو متصل کرد (Maxim Integrated, 2019). در ساخت داده‌نگار؛ از ماژول ساعت فوق دقیق DS3231 و ماژول کارت‌خوان microSD، به‌ترتیب برای ثبت زمان قرائت‌ها و ذخیره آنها روی کارت حافظه استفاده شد. همچنین؛ از یک «باتری ۱۲ ولت، ۵ آمپر-ساعت» برای فراهم‌آوردن امکان داده‌برداری در شرایط عدم دسترسی به منبع برق، استفاده شد. در شکل ۱، نمایی از نحوه اتصال ماژول‌های فوق‌الذکر و حسگرهای DS18B20 به مدار آردینو UNO را نشان می‌دهد. آرایش حسگرها درون بیرون هر پالت، به‌همراه نحوه نام‌گذاری موقعیت‌های نصب حسگرهای سخت‌افزاری، در شکل ۲-الف نشان داده شده‌است. با توجه به شکل؛ پنج حسگر در وجوه بیرونی هر پالت نصب شدند (برچسب‌های آبی‌رنگ) تا دمای اطراف پالت را بازنمایی کنند. همچنین؛ برای هر پالت سه سطح مختلف (در ارتفاع‌های ۳۰، ۶۰ و ۹۰ سانتی‌متری نسبت به کف پالت) در نظر گرفته شد و در هر سطح، چهار حسگر در چهارگوشه و یک حسگر در مرکز آن نصب شدند (برچسب‌های مشکی‌رنگ). به این ترتیب؛ امکان ثبت دما در نقاط و سطوح مختلف پالت‌ها فراهم شد (اندیس i در شکل ۲-الف، شماره‌دهنده سطح است). شکل ۲-ب تصویری از پالت اول در سردخانه را نشان می‌دهد.

کیفیت داده‌ها در توسعه یک حسگر نرم داده-محور از اهمیت زیادی برخوردار است (Lin et al., 2007)؛ لذا؛ پیش-پردازش داده‌ها نخستین گامی است که باید پس از جمع‌آوری آنها صورت گیرد (Curren et al., 2020). پیش-پردازش داده‌ها معمولاً شامل مباحثی مانند همسان‌سازی نرخ نمونه‌برداری، مواجهه با داده‌های گم‌شده و داده‌های پرت است (Souza et al., 2016). ساختار نرم‌افزاری داده‌نگار؛ ضمن همسان‌سازی نرخ داده‌برداری تمام موقعیت‌ها، امکان بروز داده‌های گم‌شده را از طریق به کارگیری «زمان‌سنج مراقب» به حداقل می‌رساند.

درباره داده‌های پرت؛ از آنجا که ممکن است ناشی از تجاوز دما از بازه مطلوب خود باشند، از حذف یا جایگزینی آنها خودداری شد (ضمن اینکه؛ هیچ مقدار «خارج از بازه منطقی»

فراابتکاری^۱ مورد ارزیابی قرار گرفت. در نهایت؛ عملکرد حسگر نرم توسعه‌یافته با یک مجموعه داده کاملاً متفاوت (به‌لحاظ شرایط دمایی و موقعیت استقرار در سالن سردخانه)، به صورت «آزمون خارج-از-نمونه^۲» ارزیابی شد.

جمع‌آوری داده‌ها

برای پیاده‌سازی مسیر توسعه حسگر نرم از دو پالت میوه هلو به‌عنوان فضای جمع‌آوری داده‌های مورد نیاز استفاده شد. محیط نگهداری پالت‌های میوه هلو یک سردخانه با ظرفیت ۲۰۰۰ تُن بود که برای فرایند تبرید از مبرد آمونیاک بهره می‌برد و دمای سالن‌های بالای صفر آن (به‌منظور نگهداری از میوه هلو) روی ۱+ درجه سلسیوس تنظیم شده بود. پالت‌های مورد استفاده در این سردخانه؛ دارای ابعاد استاندارد ۱۰۰×۱۲۰ سانتی‌متر بودند که در هر طبقه از آنها؛ میوه‌های هلو در سبدهایی به ابعاد ۲۲×۳۲ سانتی‌متر و با الگوی ۵×۳، چیده می‌شدند. پالت‌های داده‌برداری شده علاوه بر موقعیت‌های استقرار متفاوت در سالن سردخانه، تحت سناریوهای دمایی متفاوتی نیز قرار داشتند. هنگام داده‌برداری از پالت اول؛ سامانه تبرید در شرایط کارکرد صحیح قرار داشت. اما هنگام داده‌برداری از پالت دوم؛ سامانه تبرید (به منظور اجرای فرایند برفک‌زدایی) تقریباً در نیمی از بازه داده‌برداری، خاموش بود.

ساخت داده‌نگار، آرایش حسگرها، پیش‌پردازش داده‌ها

برای توسعه حسگر نرم به‌شکلی که بتواند توزیع دمای داخل پالت را به درستی درک کرده و یک برآورد دمای دقیق با وضوح مکانی بالا به دست دهد؛ لازم است هم ورودی‌های آن (نقاطی که قرار است در دنیای واقعی در آنها حسگرهای سخت‌افزاری نصب شوند) و هم خروجی‌های آن (نقاطی که قرار نیست در دنیای واقعی در آنها هیچ حسگر سخت‌افزاری نصب شود) با دقت و نرخ داده‌برداری مناسب، اندازه‌گیری و ثبت شوند. به همین منظور؛ یک داده‌نگار بر پایه فناوری آردینو ساخته شد که می‌تواند به صورت همزمان، مقادیر حداکثر ۲۰ حسگر دمای دیجیتال تنظیم‌خودکارشونده DS18B20 را با نرخ داده‌برداری یک دقیقه و دقت دو رقم اعشار، قرائت و در کارت حافظه ذخیره کند. مزیت DS18B20 آن است که علاوه بر دقت مناسب (± 0.5 درجه سلسیوس)،

² Out-of-Sample Test

¹ Meta-heuristic


و لذا تعداد حسگرهای سخت‌افزاری مورد نیاز کمتر نمی‌شود (Curreri *et al.*, 2020).

در مقابل؛ روش‌های انتخاب ویژگی، به‌جای ایجاد ویژگی‌های جدید، زیرمجموعه‌ای از ویژگی‌های اولیه را با در نظر گرفتن ارتباط بین ورودی‌ها و خروجی‌ها انتخاب می‌کنند که هم موجب کاهش تعداد ورودی‌ها می‌شود (که معادل است با کاهش حسگرهای سخت‌افزاری موردنیاز برای حسگر نرم) و هم معنای فیزیکی متغیرهای ورودی را حفظ می‌کند (Pudjihartono *et al.*, 2022; Curreri *et al.*, 2020; Benkessirat & Benblidia, 2019).

در داده‌ها مشاهده نشد). لازم است ذکر شود که داده‌ها بر حسب کلوین (که مقیاس آن نسبی است) آماده شدند تا تغییرات/ اختلافات مقادیر دما برای روش انتخاب ویژگی و الگوریتم تخمین‌گر، به درستی درک شوند.

انتخاب متغیرهای ورودی


هنگام توسعه حسگر نرم؛ به کارگیری روش‌های استخراج ویژگی دو ایراد بزرگ داشت: نخست آنکه روش‌های استخراج ویژگی، متغیرهای اولیه را به یک فضای جدید می‌برند که هیچ معنای فیزیکی ندارد و لذا تفسیر مدل را دشوارتر می‌کند. دوم آن که تعداد متغیرهای ورودی در این روش‌ها کاهش نمی‌یابد



شکل ۱- نمای نحوه اتصال ماژول‌های ساعت فوق دقیق، کارت‌خوان و حسگرهای DS18B20 به برد آردوینو.



ب



الف

شکل ۲- آرایش حسگرها در هر پالت. الف: نحوه نام‌گذاری، ب: تصویر واقعی از پالت اول.

۳- بند دوم برای مدل‌های دوم تا پنجم (Regression ، MLP ، RBF و GenLin) نیز انجام شد؛ تا امتیاز هر یک از مدل‌های مذکور به متغیرهای ورودی در تخمین متغیر هدف ، مشخص شود.

۴- «امتیاز نهایی میزان اهمیت» برای هر یک از ورودی‌ها به صورت میانگین امتیازاتش از مدل‌های فوق‌الذکر، محاسبه شد.

۵- پنج ورودی اول در تخمین متغیر هدف ، که بیش‌ترین مقادیر «امتیاز نهایی میزان اهمیت» را داشتند، مشخص و مقدار امتیاز آنها ثبت شدند.

۶- بندهای اول تا پنجم برای تمامی موقعیت‌ها (از اول تا بیستم)، انجام شدند.

۷- یک جدول امتیازات تشکیل شد، و مجموع امتیازهای تمامی موقعیت‌ها (در انتخاب به‌عنوان یک تخمین‌گر) محاسبه شدند.

۸- پنج موقعیتی که بیش‌ترین امتیازات را داشتند، به‌عنوان متغیرهای ورودی الگوریتم تخمین انتخاب شدند (موقعیت‌هایی که برای نصب حسگرهای سخت‌افزاری مناسب تشخیص داده شدند).

۹- سایر موقعیت‌ها (غیر از موارد انتخابی در بند هشتم) به‌عنوان متغیرهای خروجی الگوریتم تخمین انتخاب شدند (موقعیت‌هایی که برای برآورد دما مناسب تشخیص داده شدند).

مدل‌سازی حسگر نرم و ارزیابی آن

یک «شبکه عصبی با تأخیر زمانی» برای توسعه حسگر نرم مورد استفاده قرار گرفت که صرفاً دارای یک لایه پنهان و به صورت «چند-ورودی-چند-خروجی»^۴ است. برای اعتبارسنجی عملکرد این شبکه عصبی، از آزمون قابلیت تعمیم^۵ (۷۰ درصد آموزش، ۱۵ درصد اعتبارسنجی و ۱۵ درصد آزمون)، و برای جلوگیری از بروز بیش-برازش^۶ از روش «توقف زود هنگام»^۶، استفاده شد. از آنجا که وزن‌های اولیه شبکه به صورت تصادفی به آن اختصاص می‌یابند؛ آموزش هر

انتخاب ویژگی می‌تواند بدون مشخص کردن نقطه هدف و صرفاً با توجه به روابط آماری بین متغیرها صورت بپذیرد، یا آن‌که اهمیت تک‌تک موقعیت‌ها در برآورد یک نقطه خاص را مورد بررسی قرار دهد (نظارت‌شده باشد). در پژوهش حاضر؛ برای انتخاب متغیرهای ورودی از رویکرد «بسته‌بند»^۱ به شکل ترکیبی استفاده شد.

به طور کلی؛ رویکرد بسته‌بند در حل مسأله انتخاب ویژگی؛ اهمیت ویژگی‌ها را در قالب یک مدل ویژه، ارزیابی کرده و عملکرد آن مدل به ازای ویژگی‌های انتخابی را، بر مبنای یک معیار ارزیابی (که معمولاً میانگین مربعات خطا است) به کار می‌گیرد (Kamalov, 2018). ترکیب امتیازات مربوط به اهمیت متغیرها (که با به کارگیری مدل‌های مختلف به دست آمده باشند)، می‌تواند یک رتبه‌بندی مرکب ایجاد کرده و پایداری و قدرت فرآیند انتخاب ویژگی با رویکرد بسته‌بند را بهبود بخشد (Gyawali et al., 2022). از آنجا که داده‌های جمع‌آوری شده به‌صورت «سری‌های زمانی چندمتغیره دما»^۲ هستند؛ هیچ پیش‌فرض اولیه‌ای در یافتن بهترین نقاط برای نصب حسگرهای سخت‌افزاری وجود ندارد. لذا ضروری است فرآیند انتخاب ویژگی با رویکرد بسته‌بند برای تمامی نقاط داده‌برداری شده تکرار شده، و سپس مجموع امتیازات هر نقطه در انتخاب به‌عنوان یک ورودی با بهره اطلاعاتی بالا، مبنای انتخاب برای نصب یک حسگر سخت‌افزاری قرار بگیرد. این رویکرد نوآورانه در مقاله حاضر، «ترکیب رتبه‌بندی اهمیت ویژگی‌ها» یا به اختصار FIRE (مخفف Feature Importance Rank Ensembling) نامیده می‌شود. برای پیاده‌سازی FIRE از پنج مدل مختلف در نرم‌افزار IBM SPSS Modeler 18 استفاده شد. مراحل کار به شرح زیر بودند:

۱- یکی از موقعیت‌های قرارگیری حسگرهای سخت‌افزاری ، به عنوان متغیر هدف و سایر موقعیت‌ها به عنوان ورودی‌های آن انتخاب شد.

۲- فرآیند انتخاب ویژگی با مدل اول (Linear) انجام شد و امتیاز تمامی متغیرهای ورودی در تخمین این متغیر هدف ، مشخص شدند.

^۴ Generalization Test

^۵ Over-Fitting

^۶ Early Stopping

^۱ Wrapper

^۲ Multivariate temperature time-series

^۳ Multi-Input-Multi-Target


محاسبه شدند، ۲- مقادیر سنجه‌های R^2 ، RMSE و MAE، برای هر یک از موقعیت‌های برآورد دما در پالت محاسبه و سپس میانگین مقادیر آنها محاسبه شد. ۳- مقدار «معیار اطلاعاتی بیزیه: BIC » محاسبه شد. زیرا BIC تلاش می‌کند بین عملکرد مدل و پیچیدگی آن مصالحه برقرار کرده و نیکویی برازش را با توجه به تعداد عوامل مدل بررسی کند (Souza et al., 2016). همچنین؛ همبستگی آماری بین مقادیر سنجه‌های ارزیابی، با به کارگیری تحلیل همبستگی پیرسون^۵، در نرم‌افزار IBM SPSS Statistics 25 بررسی شد تا بتواند آن سنجه‌هایی را که اطلاعات متفاوتی به دست می‌دهند شناسایی کند و به این سؤال پاسخ دهد که: «آیا برای ارزیابی عملکرد شبکه عصبی با تأخیر زمانی لازم است از تمامی این سنجه‌ها استفاده شود؟».

با توجه به شکل ۳، شانزده مدل با پیکربندی‌های مختلف برای داده‌های هر پالت، مورد بررسی قرار گرفت. انتخاب بهترین الگوریتم تخمین‌گر (یعنی آن پیکربندی که بهترین مقادیر سنجه‌های ارزیابی را دارد)؛ از طریق «حذف کردن مدل‌های ضعیف‌تر» (Mercier & Uysal, 2018)، و با به کارگیری گام‌هایی که در ادامه آمده‌اند، صورت پذیرفت: ۱- ابتدا مدل‌هایی که مقادیر $MSE_{Validation}$ و MSE_{test} آنها بیش از ۱/۵ برابر بیش‌تر از MSE_{train} بودند، حذف شدند (زیرا این مدل‌ها یا بیش-برازش دارند یا قابلیت تعمیم ندارند و یا هر دو)، ۲- در بین مدل‌های باقیمانده، آنهایی که مقادیر $RMSE_{mean}$ و MAE_{mean} بالایی داشتند، حذف شدند، ۳- در بین مدل‌های باقیمانده نهایی، آن مدلی انتخاب شد که مقدار R^2_{mean} آن بیشینه بود. در مواردی که مقادیر $RMSE_{mean}$ ، MAE_{mean} و R^2_{mean} دو یا چند مدل به هم نزدیک بود؛ آن مدلی در اولویت قرار گرفت که ساده‌ترین معماری (مترداف با مقادیر BIC پایین‌تر) را داشته باشد.

مطالعه آماری تأثیر هر یک از فراعامل‌های الگوریتم تخمین‌گر بر مقادیر مهم‌ترین سنجه‌های ارزیابی، با به کارگیری تحلیل واریانس یک‌طرفه^۶، در نرم‌افزار IBM SPSS Statistics 25 مطالعه شد تا تأثیر انواع پیکربندی‌ها را بر

پیکربندی^۱ ۱۰ بار تکرار شد، و بهترین شبکه به دست آمده، مورد استفاده قرار گرفت.

در ابتدای کار؛ ورودی الگوریتم تخمین‌گر، داده‌های دما-زمان در پنج موقعیت انتخاب‌شده توسط FIRE، و خروجی‌های آن نیز؛ اندازه دما در سایر موقعیت‌هایی که برای برآورد دما نامزد شده بودند، انتخاب شد. سپس؛ چهار فراعامل «شبکه عصبی با تأخیر زمانی» مورد مطالعه قرار گرفتند تا بهترین ترکیب آنها، تحقیق شود: ۱- دو تأخیر زمانی مختلف (۲۰ و ۵۰ دقیقه‌ای)، ۲- دو اندازه مختلف لایه پنهان (۵ نرون و ۱۰ نرون)، ۳- دو تابع فعال‌ساز مختلف برای لایه پنهان (سیگموئید^۲: SIG و واحد یک‌سو شده خطی: ReLU) و ۴- دو روش مختلف آموزش (مارکوآرت-لونیبرگ: LM و گرادیان دیسنت^۳: GDx). شایان اشاره است؛ انتخاب این فراعامل‌ها و مقادیر آنها، بر اساس مرور منابع انجام گرفته است. به عبارتی؛ تلاش شده کلیه فراعامل‌های شناسایی‌شده در پژوهش‌های پیشین، به صورت یک‌جا (و روی یک سری داده مشخص) مورد بررسی قرار بگیرند. برای تسهیل در تشخیص تفاوت‌های بین پیکربندی مدل‌ها؛ از یک قالب نام‌گذاری به صورت نشان‌داده‌شده در شکل ۳ استفاده شد. با توجه به شکل ۳ مشاهده می‌شود که «کلیه جایگشت‌های ممکن^۴» بین فراعامل‌ها مورد بررسی قرار گرفته‌اند.



شکل ۳- قالب نام‌گذاری فراعامل‌های شبکه عصبی با تأخیر زمانی.

معیارهای مختلفی را می‌توان برای ارزیابی عملکرد یک الگوریتم تخمین‌گر در تخمین دقیق متغیرهای هدف، به کار بُرد، اما انتخاب یک الگوریتم صرفاً بر مبنای یکی از آنها، خردمندانه نیست و به کارگیری سنجه‌های مختلف می‌تواند در یک انتخاب بهتر، مفید باشد (Lim et al., 2022; Curreri et al., 2020; Tofallis, 2015). برای هریک از پیکربندی‌ها ۱- مقادیر MSE_{train} ، $MSE_{Validation}$ و MSE_{test} در مرحله پایانی

⁴ Full-Factorial Design

⁵ Pearson's Correlation Analysis

⁶ One-Way ANOVA

¹ Configuration

² Hyperbolic Tangent Sigmoid

³ Gradient descent with momentum and adaptive learning rate backpropagation

ارزیابی عملکرد حسگر نرم

سخت‌ترین شرایط برای آزمون عملکرد حسگر نرم در تخمین دمای نقاط مختلف یک پالت؛ حالتی است که در معرض داده‌هایی قرار گیرد که نه تنها در فرآیند آموزش بکار نرفته باشند، بلکه کم‌ترین شباهت را نیز با داده‌های آموزش داشته باشند. چنین آزمونی را در اصطلاح «خارج-از-نمونه» می‌نامند. به همین علت؛ از داده‌های پالت دوم برای آزمون حسگر نرم توسعه‌یافته با داده‌های پالت اول و ارزیابی قابلیت تعمیم‌پذیری آن استفاده شد (و برعکس) تا تحقیق شود که «آیا برای توسعه حسگر نرم؛ نیازی به آموزش در سناریوهای دمایی مختلف هست یا خیر؟».

لازم است ذکر شود که؛ روش پیشنهادشده برای توسعه حسگر نرم، مختص پالت‌های میوه نیست و می‌توان آن را برای سایر مسائل مربوط به افزایش وضوح مکانی پایش دما در زنجیره سرد (برای نمونه: حسگر نرم برای سنجش دمای زنجیره سرد به شکل «هر-کانتینر-یک-حسگر») نیز بکار بُرد.

نتایج و بحث

توسعه حسگر نرم با پالت اول

داده‌برداری از پالت اول پنج ساعت به طول انجامید (در حین این داده‌برداری، سامانه تبرید سردخانه در شرایط کارکرد طبیعی خود قرار داشت) جدول ۱ آن پنج موقعیتی که با استفاده از روش FIRE، بالاترین مقادیر «امتیاز نهایی میزان اهمیت» را به دست‌آوردند، اولویت‌بندی می‌کند. جدول ۲ نیز مشخصات بهترین برآزش‌های به دست آمده را با به کارگیری هریک از توابع فعال‌سازی SIG و ReLU، نشان می‌دهد. وجه اشتراک این مدل‌ها، به کارگیری روش آموزش مارکواردت-لونیبرگ و تأخیر زمانی بیست‌دقیقه‌ای است. در مقایسه توابع فعال‌سازی؛ مقادیر سنجه‌های ارزیابی برای تابع فعال‌سازی ReLU بهتر از SIG هستند. در مقابل؛ مقدار BIC شبکه‌ای که از تابع فعال‌سازی SIG بهره می‌برد، کم‌تر از مقدار آن برای تابع فعال‌سازی ReLU است. شکل ۴ تغییرات مقادیر سنجه‌های R^2_{mean} و $RMSE_{mean}$ با تغییر تعداد حسگرهای سخت‌افزاری را (بر اساس اولویت‌بندی ارائه شده در جدول ۱) در شرایطی که در بهترین پیکربندی الگوریتم تخمین‌گر (یعنی LM2010-ReLU) باشد، نشان می‌دهد. مشاهده

عملکرد شبکه عصبی با تأخیر زمانی، به ازای یک مجموعه داده یکسان، بررسی شود.

کاهش تعداد حسگرهای سخت‌افزاری موردنیاز

بدیهی است هرچه تعداد حسگرهای سخت‌افزاری بیش‌تر باشند، اطلاعات بیشتری در اختیار حسگر نرم قرار می‌گیرد (که نتیجه آن برآوردهای دقیق‌تر و بهتر است). اما؛ در شرایطی که نتوان برای هر پالت از پنج حسگر سخت‌افزاری بهره بُرد (که در عمل، با واقعیت و کاربرد عملیاتی/تجاری حسگر نرم نیز فاصله دارد)؛ باید تعداد آنها را کمینه کرد. به همین علت؛ پس از مشخص‌شدن موقعیت‌های بهینه حسگرهای سخت‌افزاری و تحقیق ترکیب مناسب فراعامل‌های الگوریتم تخمین‌گر؛ نوبت به کاهش تعداد حسگرهای سخت‌افزاری مورد نیاز برای حسگر نرم می‌رسد. ساده‌ترین راه‌حل آن است که از «امتیاز نهایی میزان اهمیت» به دست آمده از روش FIRE و رتبه‌بندی حاصل از آن استفاده شود. زیرا مزیت اصلی روش‌های انتخاب ویژگی نظارت‌شده؛ فراهم‌آوردن رتبه‌بندی میزان اهمیت متغیرهای ورودی انتخابی (در تخمین متغیرهای خروجی) است. یک سؤال مهم هنگام به کارگیری رتبه‌بندی حاصل از روش‌های انتخاب ویژگی نظارت‌شده (برای کاهش تعداد ورودی‌های الگوریتم تخمین)، میزان قابلیت اطمینان به این رتبه‌بندی است. برای پاسخ به این سؤال؛ باید موقعیت‌های انتخاب‌شده توسط روش FIRE در یک بستر مشخص (که در اینجا بهترین مدل به دست آمده بر اساس سنجه‌های ارزیابی است) با هم رقابت کرده و اولویت‌بندی شوند. لذا پنج موقعیت انتخابی توسط روش FIRE، با به کارگیری الگوریتم فراابتکاری «بهینه‌سازی کلونی مورچگان: ACO» باهم به رقابت پرداختند تا در تعداد ورودی‌های مختلف (از ۵ تا ۱ حسگر سخت‌افزاری)، $RMSE_{mean}$ الگوریتم تخمین‌گر را کمینه کنند. سپس نتایج حاصل از رتبه‌بندی مستخرج از الگوریتم ACO با رتبه‌بندی حاصل از روش FIRE مقایسه شد تا به این سوال پاسخ دهد که «در مقایسه رتبه‌بندی انجام‌شده توسط روش FIRE با ACO، کدام یک می‌تواند کم‌ترین $RMSE_{mean}$ را در حالت هر-پالت-یک-حسگر به دست آورد؟».

است. وجه اشتراک مدل‌های پالت دوم، به کارگیری روش آموزش مارکواردت-لونبرگ، تأخیر زمانی بیست‌دقیقه‌ای و استفاده از پنج نرون برای لایه پنهان است. این‌بار؛ مقادیر سنجه‌های R^2_{mean} و $RMSE_{mean}$ ، با کاهش تعداد حسگرهای سخت‌افزاری، با روند مشخص، بدتر شدند (شکل ۴).

جدول ۱- بهترین موقعیت‌ها برای نصب حسگرهای سخت‌افزاری

پالت اول					
اولویت	اول	دوم	سوم	چهارم	پنجم
موقعیت	جلو	راست	<i>In1c2</i>	<i>In1c1</i>	بالا
پالت دوم					
اولویت	اول	دوم	سوم	چهارم	پنجم
موقعیت	<i>In2c4</i>	<i>In3c4</i>	<i>In3c3</i>	راست	چپ

می‌شود که مقادیر سنجه‌های R^2_{mean} و $RMSE_{mean}$ در اولویت‌بندی مستخرج از روش FIRE، با کاهش تعداد حسگرهای سخت‌افزاری، تغییرات با روند مشخصی نداشته است.

توسعه حسگر نرم با پالت دوم

داده‌برداری از پالت دوم نیز ۵ ساعت به‌طول انجامید و در بازه زمانی مشابه با پالت اول بود (با این تفاوت که؛ سامانه تبرید سردخانه در تقریباً نیمی از این بازه زمانی، به منظور انجام فرایند برفک‌زدایی خاموش شده بود و صرفاً در دو ساعت پایانی روشن شد). نتیجه انتخاب متغیرهای ورودی با روش FIRE برای پالت دوم، در جدول ۱ آمده است. مشخصات بهترین برازش‌های به دست آمده با به کارگیری هریک از توابع فعال‌سازی SIG و ReLU نیز، در جدول ۳ نشان داده شده

جدول ۲- بهترین پیکربندی مدل به دست آمده برای پالت اول با توابع فعال‌سازی مختلف


نام ساختار مدل براساس شکل ۳	مقادیر MSE برای داده‌های:					
	آموزش	اعتبارسنجی	آزمون	$RMSE_{mean}$ [K]	MAE_{mean} [K]	R^2_{mean} [%]
<i>LM2005-SIG</i>	۰/۰۰۸	۰/۰۱۰	۰/۰۱۱	۰/۰۸۹	۰/۰۷۱	۹۶/۴۰
<i>LM2010-ReLU*</i>	۰/۰۰۴	۰/۰۰۵	۰/۰۰۶	۰/۰۶۲	۰/۰۴۸	۹۷/۶۰

* تابع فعالیت ReLU نتایج بهتری به دست می‌دهد (اگرچه اختلاف مقادیر این دو تابع فعال‌سازی، به لحاظ آماری، معنی‌دار نیست).

جدول ۳- بهترین پیکربندی مدل به دست آمده برای پالت دوم با توابع فعال‌سازی مختلف

نام ساختار مدل براساس شکل ۳	مقادیر MSE برای داده‌های:					
	آموزش	اعتبارسنجی	آزمون	$RMSE_{mean}$ [K]	MAE_{mean} [K]	R^2_{mean} [%]
<i>LM2005-SIG</i>	۰/۰۰۴	۰/۰۰۶	۰/۰۰۶	۰/۰۶۰	۰/۰۴۷	۸۴/۹۴
<i>LM2005ReLu*</i>	۰/۰۰۲	۰/۰۰۳	۰/۰۰۳	۰/۰۴۴	۰/۰۳۳	۹۰/۱۲

* تابع فعالیت ReLU نتایج بهتری به دست می‌دهد (اگرچه اختلاف مقادیر این دو تابع فعال‌سازی، به لحاظ آماری، معنی‌دار نیست).



شکل ۴- تغییرات سنجه‌های ارزیابی $RMSE_{mean}$ (سمت راست) و R^2_{mean} (سمت چپ) با کاهش تعداد حسگرهای سخت‌افزاری.

مطالعه آماری سنجه‌های ارزیابی

بررسی میزان اهمیت سنجه‌های ارزیابی معرفی شده با مطالعه همبستگی بین مقادیر این سنجه‌ها به ازای تمامی مدل‌های ایجاد شده (برای پالت‌های اول و دوم)، انجام شد و مشاهده شد که: ۱- همبستگی معنی‌داری بین مقادیر $RMSE_{mean}$ و MAE_{mean} وجود دارد و این دو سنجه، اطلاعات کاملاً مشابهی را به دست می‌دهند. از طرفی؛ ۲- همبستگی بین مقادیر MSE_{train} با $MSE_{validation}$ و MSE_{test} نیز معنی‌دار است. این در حالی است که، ۳- سنجه R^2_{mean} با هیچ‌کدام از سنجه‌های فوق‌الذکر همبستگی ندارد. ۴- سنجه BIC نیز همبستگی معناداری با سایر سنجه‌ها دارد. لذا برای ارزیابی عملکرد الگوریتم تخمین‌گر؛ استفاده از سنجه‌های MSE_{train} ، R^2_{mean} و $RMSE_{mean}$ کفایت می‌کند.

مطالعه آماری فرایمترهای الگوریتم تخمین‌گر

تأثیر فراعامل‌های الگوریتم تخمین‌گر بر مقادیر مهم‌ترین سنجه‌های ارزیابی در جدول ۴ آمده است. مشاهده می‌شود که: ۱- روش آموزش می‌تواند مقادیر MSE_{train} ، R^2_{mean} و

$RMSE_{mean}$ را به شکل معنی‌داری تحت تأثیر قرار دهد (مقادیر این سنجه‌ها، با به کارگیری الگوریتم LM بهتر می‌شوند). هم-چنین؛ ۲- اندازه لایه پنهان و تأخیرهای زمانی، صرفاً می‌توانند مقدار BIC را به شکل معنی‌داری تحت تأثیر قرار دهند (با افزایش آنها، BIC افزایش می‌یابد). ۳- تغییر تابع فعالیت، هیچ تأثیر معنی‌داری روی هیچ‌کدام از سنجه‌های ارزیابی ندارد. عدم تأثیرپذیری آماری مقادیر سنجه‌های R^2_{mean} و $RMSE_{mean}$ از تغییرات فراعامل‌های شبکه عصبی با تأخیر زمانی، با نتایج به دست آمده توسط Loisel et al. (2022) منطبق است.

ارزیابی رتبه‌بندی‌های روش FIRE

پیش‌تر، از رتبه‌بندی حاصل از روش FIRE برای کاهش تعداد حسگرهای سخت‌افزاری مورد نیاز حسگر نرم و توسعه آن به شکل «هر-پالت-یک-حسگر»، استفاده شد. برای ارزیابی/راستی‌آزمایی این رتبه‌بندی، از الگوریتم فراابتکاری بهینه‌سازی کلونی مورچگان برای هر یک از پالت‌ها استفاده شد (شکل ۵) تا بررسی شود که جایگشت‌های انتخاب شده توسط روش FIRE بهترین حالت ممکن هستند یا خیر.

جدول ۴- ارزیابی آماری فراعامل‌های شبکه عصبی با تأخیر زمانی


فراعامل	MSE_{train}	R^2_{mean}	$RMSE_{mean}$	BIC
روش آموزش	معنی‌دار*	معنی‌دار*	معنی‌دار*	معنی‌دار نیست
تابع فعال‌سازی	معنی‌دار نیست	معنی‌دار نیست	معنی‌دار نیست	معنی‌دار نیست
اندازه تأخیر زمانی	معنی‌دار نیست	معنی‌دار نیست	معنی‌دار نیست	معنی‌دار*
اندازه لایه پنهان	معنی‌دار نیست	معنی‌دار نیست	معنی‌دار نیست	معنی‌دار*

*: سطح معنی‌داری، ۹۵ درصد است.

حاصل از روش FIRE چندان قابل اعتماد نیست و به کارگیری نتایج حاصل از روش‌های فراابتکاری، خردمندانه‌تر است. مقادیر سنجه‌های ارزیابی عملکرد حسگر نرم توسعه‌یافته، به شکل «هر-پالت-یک-حسگر»، مستخرج از روش‌های FIRE و ACO برای پالت‌های اول و دوم، در جدول ۵ آمده است. مشاهده می‌شود که کم‌ترین مقدار $RMSE_{mean}$ برای هر دو پالت؛ از انتخاب موقعیت حسگر سخت‌افزاری با به کارگیری پیشنهاد مستخرج از روش ACO به دست آمده است.

نتایج نشان داد که در هیچ‌یک از موارد؛ ۱- رتبه‌بندی موقعیت‌ها توسط بهینه‌سازی کلونی مورچگان، با رتبه‌بندی مستخرج از روش FIRE هم‌خوانی ندارند. این در شرایطی است که:

۲- مقدار $RMSE_{mean}$ با به کارگیری رتبه‌بندی حاصل از بهینه‌سازی کلونی مورچگان، به شکل محسوسی کمتر از مقدار آن برای رتبه‌بندی حاصل از روش FIRE است. این مهم نشان می‌دهد که کاهش تعداد حسگرهای سخت‌افزاری مورد نیاز سامانه حسگر نرم و انتخاب موقعیت مناسب برای نصب حسگر سخت‌افزاری بصورت «هر-پالت-یک-حسگر» با رتبه‌بندی



شکل ۵- ارزیابی رتبه‌بندی حاصل از روش FIRE با الگوریتم فراابتکاری بهینه‌سازی کلونی مورچگان برای پالت اول (بالا) و پالت دوم (پایین).

هیچ اطلاعاتی از آن نداشته و در یک سناریو دمایی و موقعیت کاملاً متفاوت بوده را با خطایی در محدوده ۰/۸ تا ۱/۰ کلون تخمین بزند. که در شرایطی که امکان داده‌برداری در سناریوهای دمایی یا موقعیت‌های مختلف در زنجیره سرد امکان‌پذیر نباشد، خوشایند به نظر می‌رسد. به لحاظ ریاضی؛ این مقادیر ۱۳ تا ۱۵ برابر، بیشتر از $RMSE_{mean}$ به دست‌آمده در مرحله آموزش حسگر نرم (به ترتیب ۰/۰۷۶ و ۰/۰۵۱ کلون برای مدل‌های مستخرج از پالت‌های اول و دوم، مطابق جدول ۵) هستند. ضمن این‌که؛ مقادیر R^2_{mean} هر دو این آزمون‌ها (که به ترتیب ۰/۴۳ و ۰/۴۰ بودند) مطلوب نیست و نشان می‌دهد که حسگر نرم نتوانسته در تشخیص تغییرات سناریوی دمایی تمامی نقاط پالتی که هیچ‌گونه آموزشی درباره شرایط محیط آن نداشته است، به‌خوبی عمل کند. لذا به نظر می‌رسد برای بهبود برآوردهای حسگر نرم در شرایط واقعی / میدانی و کاهش مقدار $RMSE_{mean}$ آن؛ آموزش تحت سناریوهای دمایی متفاوت یا موقعیت استقرارهای مختلف در تجهیزات زنجیره سرد، مفید واقع شود. شکل ۶ برآورد دما در ۱۵ نقطه از پالت دوم را با به کارگیری حسگر نرم توسعه‌یافته از داده‌های پالت اول (در حالت «هر-پالت-یک-حسگر») نشان می‌دهد.


ارزیابی عملکرد حسگر نرم

برای ارزیابی عملکرد حسگر نرم توسعه‌یافته به‌شکل «هر-پالت-یک-حسگر» با به کارگیری داده‌های پالت اول، از داده‌های پالت دوم استفاده شد (و برعکس). چالش مهم برای حسگر نرم در این آزمون‌ها آن است که؛ این دو پالت در دو سناریوی دمایی مختلف و در دو موقعیت مختلف در سردخانه، داده‌برداری شده‌اند و لذا روند تغییرات دما در نقاط مختلف این دو پالت کاملاً با یکدیگر متفاوت است. این موضوع می‌تواند عملکرد حسگر نرم را به‌طور جدی تحت تأثیر قرار دهد. لذا $RMSE_{mean}$ حاصل از این آزمون، بدبینانه‌ترین حالت برای بررسی خطای حسگر نرم در برآورد دما در موقعیت‌های مختلف یک پالت در شرایطی است که نه‌تنها هیچ اطلاعات قبلی از آن ندارد؛ بلکه در شرایطی کاملاً متفاوت (با آنچه که به ازای آن آموزش دیده است) قرار گرفته است.

مقدار $RMSE_{mean}$ مدل آموزش‌دیده با داده‌های پالت اول (در برآورد دمای نقاط مختلف پالت دوم) و مدل آموزش‌دیده با داده‌های پالت دوم (در برآورد دمای نقاط مختلف پالت اول) به ترتیب برابر با ۱/۰ و ۰/۸ کلون بودند. این یعنی به لحاظ عملکرد تخمینی؛ حسگر نرم توانسته، در حالت «هر-پالت-یک-حسگر»، دمای نقاط مختلف پالتی که

جدول ۵- سنجه‌های عملکرد حسگر نرم به شکل «هر-پالت-یک-حسگر» با روش‌های مختلف

پالت مورد استفاده برای جمع‌آوری داده	روش انتخاب و موقعیت انتخاب‌شده «هر-پالت-یک-حسگر»	سنجه‌های عملکرد حسگر نرم به شکل «هر-پالت-یک-حسگر»				
		مقادیر MSE برای داده‌های:			BIC	
		آموزش	اعتبارسنجی	آزمون		
پالت اول	<i>FIRE / In2c2</i>	۰/۰۰۸	۰/۰۱۰	۰/۰۱۱	۹۵/۵۷	۰/۰۸۸
	<i>ACO / In1c2</i>	۰/۰۰۶	۰/۰۰۹	۰/۰۰۹	۹۶/۶۰	۰/۰۷۶
پالت دوم	<i>FIRE / In2c4</i>	۰/۰۲۲	۰/۰۲۸	۰/۰۳۴	۷۶/۱۶	۰/۱۰۹
	<i>ACO / راست</i>	۰/۰۰۳	۰/۰۰۴	۰/۰۰۴	۸۵/۹۰	۰/۰۵۱



شکل ۶- برآورد دمای نقاط مختلف پالت دوم با به کارگیری حسگر نرم توسعه‌یافته از داده‌های پالت اول در حالت «هر-پالت-یک-حسگر».

(در هر شکل: خط ممتد مقادیر اندازه‌گیری‌شده، و خط چین مقادیر برآوردشده هستند).

نتیجه‌گیری

نتایج این پژوهش حاکی از قابلیت بالای انتخاب ویژگی نظارت‌شده؛ به‌عنوان یک روش ساختارمند و غیرسلیقه‌ای (در تعیین بهترین موقعیت‌ها برای نصب حسگرهای سخت‌افزاری مورد نیاز)، بود. شایان اشاره است برای کاهش تعداد حسگرهای سخت‌افزاری مورد نیاز، به کارگیری سایر روش‌ها (از جمله: الگوریتم‌های فراابتکاری، یا جست‌وجوی جامع)، خردمندانه‌تر است. در همین راستا؛ به کارگیری یک روش انتخاب ویژگی نظارت‌شده دیگر و مقایسه آن با روش انجام‌شده در پژوهش حاضر، می‌تواند موضوع پژوهش‌های آینده باشد تا کیفیت رتبه‌بندی روش‌های مختلف انتخاب ویژگی نظارت‌شده را مورد بررسی قرار دهد.

ارزیابی عملکرد حسگر نرم توسعه‌یافته در قالب آزمون خارج-از-نمونه، به شکل «هر-پالت-یک-حسگر»، نشان داد که مقدار $RMSE_{mean}$ برآوردهای آن بین ۰/۸ تا ۱/۰ کلون است. چنین نتیجه‌ای برای شرایط «آموزش تحت صرفاً یک سناریو» مطلوب ارزیابی می‌شود. با این حال عواملی می‌توانند دقت برآوردها و عملکرد حسگر نرم را تحت تأثیر قرار دهند، از جمله: ۱- اندازه داده‌ها (به لحاظ مدت/ تعداد نقاط داده‌برداری)، ۲- سناریوی دمایی/ وضعیت سامانه تبرید و ۳- موقعیت پالت‌ها در سردخانه. لذا تنوع در شرایط دمایی-مکانی داده‌برداری‌ها (برای نمونه؛ داده‌برداری از دو پالت با محل استقرار متفاوت در یک سناریوی دمایی یکسان، یا داده‌برداری از یک پالت مستقر در یک نقطه و در سناریوهای دمایی مختلف) احتمالاً می‌تواند اطلاعات مفیدی برای توسعه حسگر نرم به‌دست داده و دقت برآوردهای آن را بهبود بخشند.

سپاسگزاری

نویسندگان مراتب سپاس خود را از دانشگاه تربیت مدرس بابت حمایت‌های مالی، آزمایشگاهی و فنی (پژوهانه شماره ۹۷۳۰۹۱۲۰۰۳) اعلام می‌دارند.

دسترسی به داده‌ها

داده‌های تحلیل‌شده در این پژوهش به دلیل تعهدات محرمانگی به‌صورت عمومی در دسترس نیستند، اما در صورت درخواست مراجع ذی‌مدخل از نویسنده مسئول و تایید دپارتمان قابل ارائه خواهند بود.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این پژوهش به صورت زیر است:

متین مرتضوی: ایده‌پردازی، آماده‌سازی داده‌ها، تحلیل رسمی، پژوهش، پیاده‌سازی نرم‌افزار، مصورسازی، نگارش - پیش‌نویس اولیه.

سعید مینایی: روش‌شناسی، تأمین منابع، مدیریت پروژه، جذب حمایت مالی، نگارش - بازبینی و ویرایش.

علیرضا مهدویان: روش‌شناسی، اعتبارسنجی، نظارت. محمدهادی خوش‌تقاضا: تأمین منابع، نگارش - بازبینی و ویرایش.

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر علمی رعایت نموده‌اند و این موضوع مورد تایید همه آنها است.

تضاد منافع نویسندگان

در این مقاله هیچ‌گونه تضاد منافی وجود ندارد و این مسئله مورد تایید همه نویسندگان است.

حمایت مالی

نویسنده(ها) هیچ حمایت مالی خاصی برای انجام این پژوهش دریافت نکرده‌اند.

منابع

- Badia-Melis, R., Mc Carthy, U., Ruiz-Garcia, L., Garcia-Hierro, J., & Villalba, J. R. (2018). New trends in cold chain monitoring applications-A review. *Food Control*, 86, 170-182. <https://doi.org/10.1016/j.foodcont.2017.11.022>
- Benkessirat, A., & Benblidia, N. (2019, November). Fundamentals of feature selection: an overview and comparison. In *2019 IEEE/ACS 16th International Conference on Computer Systems and Applications (AICCSA)* (pp. 1-6). IEEE. <https://doi.org/10.1109/AICCSA47632.2019.9035281>
- Brunello, A., Urgolo, A., Pittino, F., Montvay, A., & Montanari, A. (2021). Virtual sensing and sensors selection for efficient temperature monitoring in indoor environments. *Sensors*, 21(8), 2728. <https://doi.org/10.3390/s21082728>
- Curreri, F., Fiumara, G., & Xibilia, M. G. (2020). Input selection methods for soft sensor design: A survey. *Future Internet*, 12(6), 97. <https://doi.org/10.3390/fi12060097>

- (ICAISS) (pp. 1584-1587). IEEE. <https://doi.org/10.1109/ICAISS58487.2023.10250646>
- Maxim Integrated. (2019). *DS18B20 - Programmable Resolution 1-Wire Digital Thermometer*. Retrieved from DS18B20 Datasheet. <https://www.analog.com/media/en/technical-documentation/data-sheets/ds18b20.pdf>
- May, R., Dandy, G., & Maier, H. (2011). Review of input variable selection methods for artificial neural networks. *Artificial neural networks-methodological advances and biomedical applications*, 10(1), 19-45. <https://doi.org/10.5772/16004>
- Mercier, S., & Uysal, I. (2018). Neural network models for predicting perishable food temperatures along the supply chain. *Biosystems engineering*, 171, 91-100. <https://doi.org/10.1016/j.biosystemseng.2018.04.016>
- Nascimento Nunes, M. C., Nicometo, M., Emond, J. P., Melis, R. B., & Uysal, I. (2014). Improvement in fresh fruit and vegetable logistics quality: berry logistics field studies. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 372(2017), 20130307. <https://doi.org/10.1098/rsta.2013.0307>
- Perera, Y. S., Ratnaweera, D. A. A. C., Dasanayaka, C. H., & Abeykoon, C. (2023). The role of artificial intelligence-driven soft sensors in advanced sustainable process industries: A critical review. *Engineering Applications of Artificial Intelligence*, 121, 105988. <https://doi.org/10.1016/j.engappai.2023.105988>
- Pudjihartono, N., Fadason, T., Kempa-Liehr, A. W., & O'Sullivan, J. M. (2022). A review of feature selection methods for machine learning-based disease risk prediction. *Frontiers in Bioinformatics*, 2, 927312. <https://doi.org/10.3389/fbinf.2022.927312>
- Souza, F. A., Araújo, R., & Mendes, J. (2016). Review of soft sensor methods for regression applications. *Chemometrics and Intelligent Laboratory Systems*, 152, 69-79. <https://doi.org/10.1016/j.chemolab.2015.12.011>
- Stavropoulos, G., Violos, J., Tsanakas, S., & Leivadreas, A. (2023). Enabling artificial intelligent virtual sensors in an IoT environment. *Sensors*, 23(3), 1328. <https://doi.org/10.3390/s23031328>
- Swain, S., & Jenamani, M. (2022, November). Cluster analysis for identification of temperature breaks in a reefer container from IoT data. In 2022 International Conference on Futuristic Technologies (INCOFT) (pp. 1-6). IEEE. <https://doi.org/10.1109/INCOFT55651.2022.10094499>
- Gillespie, J., da Costa, T. P., Cama-Moncunill, X., Cadden, T., Condell, J., Cowderoy, T., Ramsey, E., Murphy, F., Kull, M., Gallagher, R., & Ramanathan, R. (2023). Real-time anomaly detection in cold chain transportation using IoT technology. *Sustainability*, 15(3), 2255. <https://doi.org/10.3390/su15032255>
- Gyawali, P. K., Liu, X., Zou, J., & He, Z. (2022, December). Ensembling improves stability and power of feature selection for deep learning models. In *Machine Learning in Computational Biology* (pp. 33-45). PMLR. <https://doi.org/10.48550/arXiv.2210.00604>
- Hoang, H. M., Akerma, M., Mellouli, N., Le Montagner, A., Leducq, D., & Delahaye, A. (2021). Development of deep learning artificial neural networks models to predict temperature and power demand variation for demand response application in cold storage. *International Journal of Refrigeration*, 131, 857-873. <https://doi.org/10.1016/j.jirefrig.2021.07.029>
- Kamalov, F. (2018, December). Sensitivity analysis for feature selection. In 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA) (pp. 1466-1470). IEEE. <https://doi.org/10.1109/ICMLA.2018.00238>
- Lim, M. K., Li, Y., Wang, C., & Tseng, M. L. (2022). Prediction of cold chain logistics temperature using a novel hybrid model based on the mayfly algorithm and extreme learning machine. *Industrial management & data systems*, 122(3), 819-840. <https://doi.org/10.1108/IMDS-10-2021-0607>
- Lin, B., Recke, B., Knudsen, J. K., & Jørgensen, S. B. (2007). A systematic approach for soft sensor development. *Computers & chemical engineering*, 31(5-6), 419-425. <https://doi.org/10.1016/j.compchemeng.2006.05.030>
- Loisel, J., Cornuéjols, A., Laguerre, O., Tardet, M., Cagnon, D., de Lamotte, O. D., & Duret, S. (2022). Machine learning for temperature prediction in food pallet along a cold chain: Comparison between synthetic and experimental training dataset. *Journal of Food Engineering*, 335, 111156. <https://doi.org/10.1016/j.jfoodeng.2022.111156>
- Loisel, J., Duret, S., Cornuéjols, A., Cagnon, D., Tardet, M., Derens-Bertheau, E., & Laguerre, O. (2021). Cold chain break detection and analysis: Can machine learning help? *Trends in Food Science & Technology*, 112, 391-399. <https://doi.org/10.1016/j.tifs.2021.03.052>
- Maruthi, R., Lakshmi, I., & Devi, V. D. (2023, August). Monitoring Perishable Foods using Machine Learning and Internet of Things. In 2023 Second International Conference on Augmented Intelligence and Sustainable Systems

- Tofallis, C. (2015). A better measure of relative prediction accuracy for model selection and model estimation. *Journal of the Operational Research Society*, 66(8), 1352-1362. <https://doi.org/10.1057/jors.2014.103>
- Xu, F., Sato, Y., Sakai, Y., Sabu, S., Kanayama, H., Satou, D., & Kansha, Y. (2022). A Prediction Model for Temperature Variation and Distribution Using Soft Sensing Method. *Chemical Engineering Transactions*, 94, 811-816. <https://doi.org/10.3303/CET2294135>
- Zou, Y., Wu, J., Wang, X., Morales, K., Liu, G., & Manzardo, A. (2023). An improved artificial neural network using multi-source data to estimate food temperature during multi-temperature delivery. *Journal of Food Engineering*, 351, 111518. <https://doi.org/10.1016/j.jfoodeng.2023.111518>