



Research paper

(Received 31 Aug. 2025

Accepted 28 Nov. 2025)

Presenting a hybrid method based on deep learning to predict the Universal Thermal Climate Index in urban open spaces

Azam Noroozi¹, Mohammad Mohammadi²

¹ *Department of Civil Engineering and Architecture, Faculty of Engineering, University of Torbat Heydarieh, Torbat Heydarieh, Iran*

² *Department of Computer Engineering, Bozorgmehr University of Qaenat, Qaen, Iran*

Abstract

The increasing growth of urbanization and climate challenges have made the creation of sustainable urban environments an important issue in recent years. The design of sustainable spaces has become of great importance due to the impact of thermal comfort in urban open spaces on the feeling of comfort and satisfaction of citizens, as well as the optimal use of environmental conditions in creating comfort and saving energy consumption. Accurate prediction of thermal comfort and environmental thermal conditions in urban areas by various methods facilitates the improvement of urban planning and energy management. A review of previous studies shows the high ability of deep learning models in improving thermal comfort predictions. In this paper, a hybrid method based on deep learning is presented for predicting the universal thermal climate index. After preprocessing the dataset, the previous models that had high accuracy were trained and evaluated. Then, the three models with the highest performance were selected for the combined model, and the predictions of all three models were generated for the test set. To ensure dimensionality integrity, the predictions were converted into one-dimensional arrays. Finally, the final prediction was calculated by averaging the predictions of the three models. To evaluate the performance of the proposed model and to train and test the methods used in the combined model, the real data set of Mashhad city was used. Standard numerical prediction criteria including root mean square error, mean absolute error and coefficient of determination were calculated to evaluate the proposed model. The evaluation results showed that the hybrid model provides better performance in predicting the universal thermal climate index compared to previous methods.

Keywords: Urban open space, thermal comfort, Universal Thermal Climate Index (UTCI) prediction.



مقاله پژوهشی

تاریخ پذیرش: ۱۴۰۴/۸/۶

تاریخ دریافت: ۱۴۰۴/۶/۹

ارائه یک روش ترکیبی مبتنی بر یادگیری عمیق برای پیش‌بینی شاخص جهانی اقلیم حرارتی در فضای باز شهری

اعظم نوروزی^{۱*}، محمد محمدی^۲

^۱استادیار، گروه عمران و معماری، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران.

^۲دانشجوی کارشناسی ارشد، دانشکده فنی و مهندسی، دانشگاه بزرگمهر قائنات، قاین، ایران

چکیده

رشد روزافزون شهرنشینی و چالش‌های اقلیمی، ایجاد محیط‌های شهری پایدار را به موضوعی مهم در سال‌های اخیر تبدیل کرده است. طراحی فضای پایدار به دلیل تأثیر آسایش حرارتی در فضای باز شهری بر احساس آسایش و رضایت شهروندان و همچنین استفاده بهینه از شرایط محیطی در ایجاد آسایش و صرفه‌جویی انرژی اهمیت زیادی داشته است. پیش‌بینی دقیق آسایش حرارتی و شرایط حرارتی محیطی در مناطق شهری با روش‌های مختلف، بهبود برنامه‌ریزی شهری و مدیریت انرژی را تسهیل می‌نماید. بررسی مطالعات پیشین نشان‌دهنده توانایی بالای مدل‌های یادگیری عمیق در بهبود پیش‌بینی‌های آسایش حرارتی است. در این مقاله یک روش ترکیبی مبتنی بر یادگیری عمیق برای پیش‌بینی شاخص جهانی اقلیم حرارتی ارائه شده است. در این مقاله بعد از پیش‌پردازش مجموعه داده، مدل‌های قبلی که دقت بالایی داشته‌اند آموزش داده شده و مورد ارزیابی قرار گرفتند. سپس سه مدل با بالاترین عملکرد برای مدل ترکیبی انتخاب شده و پیش‌بینی‌های هر سه مدل برای مجموعه تست تولید و برای اطمینان از یکپارچگی ابعاد، پیش‌بینی‌ها به آرایه‌های یک‌بعدی تبدیل شدند. در نهایت پیش‌بینی نهایی از میانگین‌گیری پیش‌بینی‌های سه مدل محاسبه شد. مجموعه داده‌های واقعی مربوط به شهر مشهد برای ارزیابی عملکرد مدل پیشنهادی و آموزش و آزمایش روش‌های استفاده شده در مدل ترکیبی بکارگرفته شد. معیارهای استاندارد پیش‌بینی عددی شامل ریشه میانگین مربعات خطا، میانگین مطلق خطا و ضریب تعیین برای ارزیابی مدل پیشنهادی محاسبه شد. نتایج ارزیابی نشان داد که مدل ترکیبی با مقادیر $RMSE^1=0.963$ ، $MAE^2=0.711$ و $R2^3=0.994$ عملکرد بهتری در پیش‌بینی شاخص جهانی اقلیم حرارتی در مقایسه با روش‌های پیشین ارائه می‌دهد.

کلمات کلیدی: فضای باز شهری، آسایش حرارتی، پیش‌بینی شاخص جهانی اقلیم حرارتی.

Doi: 10.48306/juem.2025.544353.1094

* نویسنده مسئول: اعظم نوروزی

ایمیل: a.noroozi@torbath.ac.ir

شماره تماس: ۰۹۱۵۴۶۲۸۷۳۰

¹Root Mean Square Error (RMSE)

²Mean Absolute Error (MAE)

³R-Squared (R2)

۱- مقدمه

پایداری محیط زیست و مواجهه با چالش‌های اقلیمی از موضوعات مورد مطالعه در دهه‌های اخیر است. ایجاد محیط‌های شهری پایدار که نتنها با تغییرات اقلیمی سازگار باشد که اثرات منفی آن را کاهش دهد زمینه ساز زندگی پایدار خواهد بود [۱]. توجه به طراحی یک فضا اولین گام در ایجاد فضا متناسب با شرایط محیطی و اقلیمی است که با هدف استفاده بهینه از شرایط محیطی در ایجاد آسایش و صرفه‌جویی انرژی انجام می‌شود. در حال حاضر، بیش از نیمی از جمعیت جهان در مناطق شهری زندگی می‌کنند و پیش‌بینی می‌شود که این نسبت تا سال ۲۰۵۰ به ۶۸٪ برسد [۲]. با توجه به رشد روزافزون فضاهای باز شهری به دلیل گسترش شهرنشینی و همچنین گرمایش زمین، تأثیر آسایش حرارتی در فضای باز شهری بر احساس آسایش و رضایت شهروندان آشکار می‌گردد [۳]. آسایش محیطی از مؤلفه‌های مهم و اساسی محیط‌های انسان‌ساخت محسوب می‌شوند که با پدیده‌هایی چون آلودگی‌های محیط زیستی یا پدیده آلودگی‌های رفتاری و اجتماعی در فضاهای شهری در ارتباط است [۴]. افزایش کیفیت فضاهای عمومی، بعنوان فضای مؤثر در کشف و ادراک محیط کالبدی و اجتماعی شهر، امکانات آسایش روانی انسان‌ها در فضای همگانی را افزایش می‌دهد.

عوامل اقلیمی تعریف کننده ریزاقلیم‌ها در فضای شهری هستند و با زندگی انسان‌ها رابطه‌ای کاملاً نزدیک دارند. این شرایط و تغییراتی که به واسطه تغییرات در طراحی شهری در ریزاقلیم‌ها بوجود می‌آید تأثیر زیادی بر انسان و آسایش او ایجاد می‌کند. شناخت این تغییرات در فضاهای شهری موجب تأمین آسایش محیطی فضاهای شهری و در نتیجه، آسایش انسان می‌گردد [۵]. علاوه بر این قرار گرفتن افراد در شرایط نامطلوب آب و هوایی به مدت طولانی سبب ایجاد بیماری‌های مختلفی مانند گرم‌زدگی، کم‌آبی بدن و مشکلات تنفسی می‌شود. به همین دلیل درک جامع عوامل مؤثر بر آسایش حرارتی در فضای باز و طراحی راه کارهای مؤثر در بهبود آسایش حرارتی، امری ضروری و حیاتی است [۳].

پیش‌بینی دقیق آسایش حرارتی و شرایط حرارتی محیطی در مناطق شهری با روش‌های مختلف، بهبود برنامه‌ریزی شهری و مدیریت انرژی را تسهیل می‌نماید. این پژوهش در جستجوی ارائه‌ی یک مدل برای بهبود پارامترهای پیش‌بینی شاخص جهانی اقلیم حرارتی^۱ نسبت به مدل‌های پیشین می‌باشد. این تحقیق در جستجوی یافتن پاسخ سه پرسش می‌باشد.

۱. آیا استفاده از الگوریتم‌های یادگیری عمیق و شبکه‌های عصبی، باعث بهبود پارامترهای پیش‌بینی شاخص‌های آسایش حرارتی در فضای شهری می‌گردد؟

۲. چه روش‌هایی مبتنی بر یادگیری عمیق در پیش‌بینی بهتر UTCI استفاده می‌شود؟

۳. آیا ترکیب این روش‌ها عملکرد مدل را بهبود می‌بخشد؟

انتظار می‌رود که مدل‌های یادگیری عمیق توانایی بالایی در بهبود پیش‌بینی‌های آسایش حرارتی داشته باشد. همچنین یک روش ترکیبی عملکرد بهتری برای پیش‌بینی شاخص UTCI در پارامترهای مختلف ارزیابی نسبت به روش‌های پیشین داشته باشد.

۱-۱- پیشینه تحقیق

روش‌های مختلفی برای برآورد شاخص UTCI وجود دارد اما پژوهشگران روش‌های مبتنی بر هوش مصنوعی را جایگزین روش‌های سنتی مثل شبیه‌سازی عددی و روش‌های آماری می‌دانند و علت را افزایش چشم‌گیر سرعت و کارایی آن بیان می‌کنند [۶] و [۷]. کرمانووی و همکاران [۸] مدلی را در کشور اسلوانی برای پیش‌بینی UTCI ارائه کردند. این مدل از داده‌های هفت ساله ۴۲ ایستگاه هواشناسی برای اعتبارسنجی پیش‌بینی عملیاتی UTCI و بهبود پیش‌بینی از طریق پس پردازش استفاده می‌کرد. دو روش یادگیری ماشین رگرسیون خطی و شبکه عصبی مورد استفاده قرار گرفت و هر دو روش به‌طور موفقیت‌آمیز خطای پیش‌بینی عملیاتی UTCI را کاهش دادند، به‌طوری که میانگین خطای روزانه از حدود ۲/۶ درجه سانتی‌گراد به نزدیک صفر رسید. میانگین خطای مطلق روزانه نیز به ترتیب به ۳ درجه برای شبکه عصبی و ۳/۵ درجه برای رگرسیون خطی کاهش یافت. علاوه بر این، وابستگی خطا به زمان روز به‌ویژه در روش شبکه عصبی به‌طور چشمگیری کاهش یافت.

^۱Universal Thermal Climate Index (UTCI)

^۲Post-processing

در پژوهشی که ریشیکا شاه و همکاران [۹] در منطقه گوالیار هند انجام دادند، دو مدل شبکه عصبی مصنوعی^۱ برای پیش‌بینی شاخص‌های راحتی حرارتی مورد استفاده قرار گرفتند که ضریب تعیین^۲ آن‌ها دو ۹۹ درصد بوده است. در یک مدل، پارامترهایی همچون دمای هوا، سرعت باد، رطوبت نسبی و دمای تابش متوسط به همراه تاریخ و زمان مورد استفاده قرار گرفت و در مدل دیگر، فقط دمای هوا مورد استفاده قرار گرفت و شاخص‌های دمای معادل فیزیولوژیک^۳ و UTCI را به صورت ساعتی پیش‌بینی کردند. نتایج نشان داد که حتی مدل ساده‌تر که تنها از دمای هوا به عنوان ورودی استفاده می‌کند، عملکرد قابل قبولی داشته و پیش‌بینی‌های قابل اعتماد ارائه داده است. همچنین شاخص UTCI دقت پیش‌بینی بهتری نسبت به PET داشت و تقریباً ۶ تا ۸ درصد عملکرد بهتری نشان داد.

فردیناند بریگل و همکاران [۱۰] در یک منطقه شهری در آلمان، یک مدل یادگیری ماشین برای شبیه‌سازی چند مدل اقلیم شهری ارائه کردند که شامل ۴ زیر مدل مجزا برای پیش‌بینی دمای هوا، رطوبت نسبی، سرعت باد و دمای تابش متوسط بر اساس داده‌های هواشناسی و اطلاعات جغرافیایی از اشکال ساختمان‌ها، پوشش زمین و پوشش گیاهی بود. سپس این متغیرها در شاخص حرارتی UTCI ترکیب شدند. با استفاده از داده‌های حسگرهای سطح خیابان در شبکه حسگر متراکم شهری ارزیابی مدل انجام شد و خطای مطلق میانگین^۴ مدل نهایی برابر ۲/۳ کلون و مقدار میانگین مربع خطا^۵ برابر ۳ محاسبه شد. شبیه‌سازی‌های انجام شده نشان می‌دهند که مدل به اندازه کافی سریع و انعطاف‌پذیر بوده و می‌تواند داده‌های چندین سال را با گام‌های زمانی یک ساعته برای پیش‌بینی شاخص UTCI در مقیاس فضایی ۱ متر در کل شهر پردازش کند.

ژی‌وی یانگ و همکاران [۱۱] با تولید مجموعه داده GloUTCI-M و استفاده از الگوریتم‌های یادگیری ماشین مختلف در نهایت به مدل CatBoos با MAE برابر ۰/۷۴۷ درجه سانتیگراد، R^2 برابر ۰/۹۹۱ و RMSE بالاتر از ۱/۰ سانتیگراد برای پیش‌بینی شاخص UTCI رسیدند که از سایر الگوریتم‌های یادگیری ماشین مورد استفاده بهتر بود. همچنین گوئودونگ ژونگ [۱۲] تلاش کرد با استفاده از ترکیب الگوریتم‌های یادگیری ماشین و تحلیل فضایی، مدل‌هایی بسازد که بتوانند به شکل دقیق‌تری شرایط حرارتی فضاها را مانند پیش‌بینی (UTCI) را شبیه‌سازی کنند. برای این کار، دو شبکه عصبی با ساختار و پارامترهای مختلف طراحی و آزمایش شدند. نتایج نشان داد با تنظیم مناسب ساختار شبکه و افزایش داده‌های آموزشی، می‌توان به مدل‌هایی دقیق‌تر دست یافت.

بررسی مطالعات ذکر شده نشان‌دهنده توانایی بالای مدل‌های یادگیری عمیق در بهبود پیش‌بینی‌های آسایش حرارتی است. این مقاله سعی کرده است یک روش ترکیبی برای پیش‌بینی شاخص UTCI ارائه کند که عملکرد بهتری نسبت به روش‌های پیشین در پارامترهای مختلف ارزیابی داشته باشد.

۲- مواد و روشها

در پژوهش انجام شده، یادگیری عمیق به عنوان یک ابزار قدرتمند در تحلیل و پیش‌بینی پارامترهای محیطی مورد استفاده قرار گرفته است. ابتدا با بررسی مطالعات پیشین، مدل‌های مبتنی بر یادگیری عمیق در پیش‌بینی شاخص UTCI شناسایی گردید. این مدل‌ها در شرایط یکسان با مجموعه داده پیش‌پردازش شده، مورد ارزیابی قرار گرفت. داده‌ها از یک مجموعه داده جامع از شرایط آب‌وهوایی شهر مشهد و تبریز، مربوط به ۵ سال گذشته، جمع‌آوری و پیش‌پردازش آن به منظور بهینه‌سازی کیفیت ورودی‌ها و کاهش نویز انجام گرفت. پس از ارزیابی الگوریتم‌ها، سه روش با بهترین عملکرد در معیار RMSE شناسایی و برای استفاده در روش ترکیبی انتخاب شد. در نهایت با استفاده از یک روش ترکیبی، مدلی ارائه شد که شاخص UTCI را با دقت مناسب پیش‌بینی نماید و این مدل مورد ارزیابی قرار گرفت.

^۱Artificial Neural Network (ANN)

^۲R-Squared (R^2)

^۳Physiological equivalent temperature (PET)

^۴Mean Absolute Error (MAE)

^۵Root Mean Square Error (RMSE)

۲-۱- مبانی نظری

آسایش حرارتی به معنی شرایطی ذهنی است که در آن فرد احساس تعادل دمایی با محیط اطراف دارد [۱۳]. این مفهوم هم در داخل ساختمان و هم در فضای باز مطرح است، اما با توجه به شرایط مختلف محیطی، عوامل مؤثر و راهکارهای تأمین آن متفاوت است. بررسی مقالات مختلف این حوزه نشان می‌دهد که آسایش حرارتی تنها به دمای هوا وابسته نبوده، بلکه تحت تأثیر عوامل فیزیکی، فیزیولوژیکی و روانشناختی به صورت مستقیم و عوامل دیگری چون اجتماعی، فرهنگی و ویژگیهای سایت نیز بطور غیرمستقیم می‌باشد. عوامل فیزیکی شرایط محیطی رطوبت نسبی، سرعت هوا، و میانگین دمای تابشی و دمای هوا که به شرایط آب و هوایی منطقه وابسته است را دربر می‌گیرد [۱۴]. تحقیقات نشان داده است که می‌توان شرایط محیطی و به واسطه آن آسایش حرارتی در فضای باز را از طریق ادغام راه‌حل‌های طراحی مانند بام‌های سبز، پارک‌های شهری، آب‌نماها و درختکاری بهبود بخشند تا اثر جزیره گرمایی شهری را کاهش دهند و کیفیت کلی محیط زیست را ارتقا دهند [۱۳]. سه رویکرد اصلی در ارزیابی آسایش حرارتی وجود دارد. نخست تعادل حرارتی، دوم رویکرد تطبیقی و رویکرد نهایی آسایش حرارتی شخصی می‌باشد [۱۵]. در مدل نخست، آسایش حرارتی به عنوان پدیده ای فیزیکی-فیزیولوژیکی در نظر گرفته شده و احساس حرارتی انسان از انتقال حرارت بین بدن انسان و محیط بیان می‌شود. رویکرد تطبیقی نیز با توجه به توانایی ذاتی افراد در سازگاری با شرایط محیطی متغیر به ویژه در ساختمان‌های با تهویه طبیعی، دمای آسایش را به عنوان تابعی از دمای هوای بیرون در نظر می‌گیرد. همچنین در رویکرد سوم، آسایش به معنای در نظر گرفتن ترجیحات و نیازهای حرارتی فردی در محیط‌های داخلی است تا احساس راحتی و رضایت حرارتی برای هر شخص به حداکثر برسد. همچنین در سالهای اخیر، پژوهش‌های زیادی در موضوع بررسی پیچیدگی‌های آسایش حرارتی در فضاهای باز انجام شده است. در تحقیقات انجام شده به منظور ارزیابی آسایش حرارتی در فضاهای باز شهری از شاخص‌های گوناگون بهره گرفته‌اند. شاخص‌های مختلف آسایش حرارتی نظیر دمای مؤثر استاندارد (SET)، شاخص جهانی اقلیم حرارتی (UTCI) و دمای معادل فیزیولوژیکی (PET) برای ارزیابی انواع محیط‌های بیرونی استفاده شده است [۱۳].

شاخص جهانی اقلیم حرارتی (UTCI)، یک شاخص برای ارزیابی احساس حرارتی انسان در فضاهای بیرونی است و برای هر آب و هوا، فصل یا مقیاس مشخص محیط حرارتی را تخمین می‌زند. این شاخص یک دمای معادل (C°) است که معیاری از پاسخ فیزیولوژیکی انسان به محیط حرارتی بوده و تبادلات حرارتی هم‌افزایی بین محیط حرارتی و بدن انسان، یعنی بودجه انرژی، فیزیولوژی و لباس آن را توصیف می‌کند. هدف توسعه‌دهندگان UTCI این بود که شاخصی برای سنجش احساس حرارتی انسان ارائه دهند که قابلیت کاربرد جهانی داشته باشد [۱۶]. پژوهش‌ها نشان داده که UTCI با بسیاری از شاخص‌های راحتی دیگر مثل PMV، SET و PET حدود ۹۶٪ ارتباط دارد. علاوه بر این UTCI نسبت به تغییرات زمانی در عناصر جوی حساس‌تر از سایر شاخص‌های راحتی است. این شاخص به وضوح نوسانات جزئی در احساس راحتی انسان را که به تغییرات آب‌وهوایی پاسخ می‌دهد، نشان می‌دهد و تاثیر زیادی در تصمیم‌گیری‌های معماران و شهرسازان دارد [۱۷].

۲-۱- منطقه مورد مطالعه

شهر مشهد، مرکز استان خراسان رضوی با موقعیت موقیعت ۳۶ درجه و ۱۶ دقیقه عرض شمالی و ۵۹ درجه و ۳۸ دقیقه طول شرقی در بخش بزرگی از حوضه آبریز کشف رود به ارتفاع متوسط ۹۴۳ متر از سطح دریا واقع گردیده است. شهر تبریز، دومین شهر مورد مطالعه و مرکز استان آذربایجان شرقی است. موقعیت جغرافیایی تبریز در ۳۸ درجه و چهار دقیقه عرض شمالی و ۴۶ درجه و ۱۷ دقیقه طول شرقی می‌باشد. تبریز از سمت شمال، جنوب و شرق به کوهستان و از سمت غرب به دشت هموار تبریز محدود شده و ارتفاع آن از ۱۳۴۸ متر تا ۱۵۶۱ متغیر است. در این مطالعه برای آماده سازی یک مدل برای پیش‌بینی شاخص UTCI از داده‌های موجود در یک مجموعه داده هواشناسی محلی شهر مشهد و تبریز که از سایت SOLCAST تهیه شده استفاده شده است [۱۸]. این مجموعه داده شامل اطلاعات ساعتی برای دوره‌ای مشخص از شرایط آب و هوای شهر مشهد و تبریز می‌باشد که از ۵ سال گذشته جمع‌آوری شده است.

۳- بحث و نتایج

۳-۱- داده‌ها و آماده‌سازی

داده‌های مورد استفاده در این مطالعه شامل چهار متغیر دمای هوا (air temp) به درجه سانتی‌گراد، رطوبت نسبی (relative humidity) به درصد، سرعت باد در ارتفاع ۱۰ متری (wind_speed_10m) به متر بر ثانیه و تابش جهانی خورشیدی (ghi) به وات بر مترمربع است. جدول ۱ اطلاعات ستون‌ها، نوع داده‌ها و تعداد مقادیر غیر خالی هر ستون مجموعه داده را نشان می‌دهد. برای اطمینان از دقت محاسبات، مقادیر سرعت باد که خارج از محدوده طبیعی (بزرگ‌تر از ۱۷ متر بر ثانیه) بودند، به حداکثر مقدار مجاز (۱۷ متر بر ثانیه) محدود شدند تا نویزهای احتمالی حذف گردند.

جدول ۱- اطلاعات ستون‌ها، نوع داده‌ها و تعداد مقادیر غیر خالی مجموعه داده هواشناسی.

Column	Data Type	Non-Null Count
air_temp	int64	36336
albedo	float64	36336
azimuth	int64	36336
clearsky_dhi	int64	36336
clearsky_dni	int64	36336
clearsky_ghi	int64	36336
clearsky_gti	int64	36336
cloud_opacity	float64	36336
dewpoint_temp	float64	36336
dhi	int64	36336
dni	int64	36336
ghi	int64	36336
gti	int64	36336
precipitable_water	float64	36336
precipitation_rate	float64	36336
relative_humidity	float64	36336
surface_pressure	float64	36336
snow_depth	float64	36336
snow_water_equivalent	float64	36336
snow_soiling_rooftop	int64	36336
snow_soiling_ground	int64	36336
wind_direction_100m	int64	36336
wind_direction_10m	int64	36336
wind_speed_100m	float64	36336
wind_speed_10m	float64	36336

Column	Data Type	Non-Null Count
zenith	int64	36336
period_end	object	36336
period	object	36336

۳-۲- پیش پردازش داده‌ها

پیش پردازش داده‌ها با هدف بهینه‌سازی کیفیت ورودی‌ها و کاهش نویز انجام شد. برای پیش‌بینی سری‌های زمانی، یک پنجره زمانی لغزنده با طول ثابت $T=12$ (معادل ۱۲ بازه ساعتی) تعریف شد [۱۹]. این انتخاب بر اساس تحلیل اولیه الگوهای آب‌وهوایی انجام گرفت، که نشان داد دوره‌های ۱۲ ساعته قادر به ضبط تغییرات کوتاه‌مدت و میان‌مدت در متغیرهای هواشناسی (مانند دما و تابش خورشیدی) هستند. تابع `create sequences` به صورت زیر پیاده‌سازی شد.

$$X_t = [x_{t-T+1}, x_{t-T+2}, \dots, x_t], y_t = x_{t+1} \quad (1)$$

که در آن X_t ماتریس ویژگی‌های ورودی برای زمان t و مقدار هدف (UTCI) برای زمان بعدی است. این تبدیل منجر به تولید ۳۴۵۱۲ نمونه آموزشی و آزمایشی شد، که ۸۰٪ آن‌ها (۲۷۶۰۹ نمونه) برای مجموعه آموزشی و ۲۰٪ باقی‌مانده (۶۹۰۳ نمونه) برای مجموعه آزمایشی تخصیص یافتند.

برای استانداردسازی مقیاس داده‌ها و بهبود فرآیند بهینه‌سازی شبکه، از تکنیک نرمال‌سازی مینیمم-ماکزیمم استفاده شد [۲۰]. این روش داده‌ها را به بازه $[0, 1]$ نگاشت می‌دهد و به صورت زیر تعریف می‌شود.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

که در آن x مقدار اولیه، x_{min} و x_{max} به ترتیب حداقل و حداکثر مقادیر هر ویژگی در مجموعه داده هستند، x' مقدار نرمال شده است.

این فرآیند با استفاده از کلاس `MinMaxScaler` از کتابخانه `scikit-learn` پیاده‌سازی شد و به صورت جداگانه برای هر متغیر دما، رطوبت نسبی، سرعت باد، تابش خورشیدی، و (UTCI) اعمال گردید. نرمال‌سازی از اثرگذاری نامتناسب متغیرهایی با دامنه‌های متفاوت (مانند `ghi` با مقیاس وات بر مترمربع در مقابل `air temp` با مقیاس درجه سانتی‌گراد) جلوگیری کرد و به تثبیت گرادیان‌ها در الگوریتم بهینه‌سازی کمک نمود.

۳-۳- روش ترکیبی پیشنهادی

در مرحله اول مجموعه داده پیش پردازش شده که به دو مجموعه داده ثابت آموزش و تست با نسبت ۸۰ به ۲۰ تقسیم گردید را با الگوریتم‌های مورد استفاده در بخش کارهای پیشین در شرایط کاملاً یکسان با مجموعه داده آموزش، آموزش داده و با مجموعه داده تست مورد ارزیابی قرار گرفت.

ارزیابی عملکرد مدل‌ها با استفاده از معیارهای استاندارد پیش‌بینی عددی، یعنی ریشه میانگین مربعات خطا (RMSE) و میانگین مطلق خطا (MAE) انجام شد. این معیارها به ترتیب حساسیت به خطاهای بزرگ و میانگین خطاهای پیش‌بینی را اندازه‌گیری می‌کنند و به صورت زیر تعریف می‌شوند.

'sliding window

'Min-Max Normalization

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (۳)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (۴)$$

که در آن y_i مقدار واقعی UTCI، \hat{y}_i مقدار پیش‌بینی شده و n تعداد نمونه‌های مجموعه آزمایشی (۶۹۰۳ نمونه) است. علاوه بر این، برای تحلیل دقیق‌تر خطاها، ضریب تعیین R^2 نیز محاسبه شد که میزان تطابق بین مقادیر پیش‌بینی شده و واقعی را نشان می‌دهد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (۵)$$

که در آن \bar{y} میانگین مقادیر واقعی است. این معیار مقداری بین ۰ و ۱ دارد و مقادیر نزدیک به ۱ نشان‌دهنده عملکرد بهتر مدل است. پیش‌بینی‌های مدل با داده‌های مجموعه تست (۲۰٪ از کل داده‌ها، معادل ۶۹۰۳ نمونه) انجام شد. برای اطمینان از مقیاس‌پذیری نتایج، مقادیر نرمال‌شده خروجی مدل با استفاده از معکوس نرمال‌سازی مینیمم-ماکزیمم به مقادیر واقعی UTCI تبدیل شدند. نتایج ارزیابی اجرای شبکه‌های مورد استفاده در بخش کارهای پیشین در جدول ۲ نشان داده شده است.

جدول ۲- معیارهای ارزیابی به دست آمده از اجرای الگوریتم‌های بخش کارهای پیشین روی مجموعه داده مقاله، مرتب شده براساس بهترین مقدار معیار ارزیابی RMSE.

Model	RMSE	MAE	R ²
Rishika Shah et al. [8] - Network A	0.975	0.715	0.994
Ferdinand Briegel et al. [9] - HTC-NN	0.978	0.736	0.994
Rishika Shah et al. [8] - Network B	0.988	0.742	0.993
Ferdinand Briegel et al. [9] - SOLWEIG	1.002	0.767	0.993
Zhiwei Yang et al. [10] - CatBoost	1.033	0.756	0.993
Zhiwei Yang et al. [10] - LightGBM	1.098	0.789	0.992
Zhiwei Yang et al. [10] - XGBoost	1.104	0.809	0.992
Kozmanovic et al. [7] - LR	1.689	1.261	0.981
Kozmanovic et al. [7] - NN	2.002	1.505	0.973

با توجه به نتایج ارائه شده در جدول ۲، سه روش اول برای استفاده در یک روش ترکیبی، برای پیش‌بینی UTCI انتخاب شد.

۳-۴- معماری شبکه‌های مورد استفاده

چنانچه در بالا اشاره گردید، سه مدل شبکه عصبی با معماری‌های متفاوت برای پیش‌بینی UTCI انتخاب شد.

Network A-۱-۴-۳

شامل سه لایه مخفی با ۱۵۰، ۱۰۰ و ۵۰ نرون و تابع فعال‌سازی ReLU، که برای یادگیری الگوهای پیچیده طراحی شده است.

HTC-NN-۲-۴-۳

شامل سه لایه مخفی با ۱۰۰، ۵۰ و ۲۵ نرون و تابع فعال‌سازی ReLU، که تعادلی بین پیچیدگی و کارایی ارائه می‌دهد.

Network B-۳-۴-۳

شامل دو لایه مخفی با ۵۰ و ۲۵ نرون و تابع فعال‌سازی ReLU، که برای کاهش پیچیدگی محاسباتی مناسب است.

هر سه مدل با استفاده از بهینه‌ساز Adam و برای ۱۰۰ دوره^۱ و اندازه دسته برابر ۳۲ با داده‌های آموزش نرمال‌شده آموزش دیده و برای پیش‌بینی UTCI در مجموعه تست آماده گردید. پیش‌بینی‌های هر سه مدل (Network A، HTC-NN و Network B) برای مجموعه تست تولید و برای اطمینان از یکپارچگی ابعاد، پیش‌بینی‌ها به آرایه‌های یک‌بعدی تبدیل شدند^۲. در نهایت پیش‌بینی نهایی (y_pred_ensemble) از میانگین‌گیری پیش‌بینی‌های سه مدل محاسبه شد. جدول ۳ پارامترهای آموزش مدل‌ها را نشان می‌دهد.

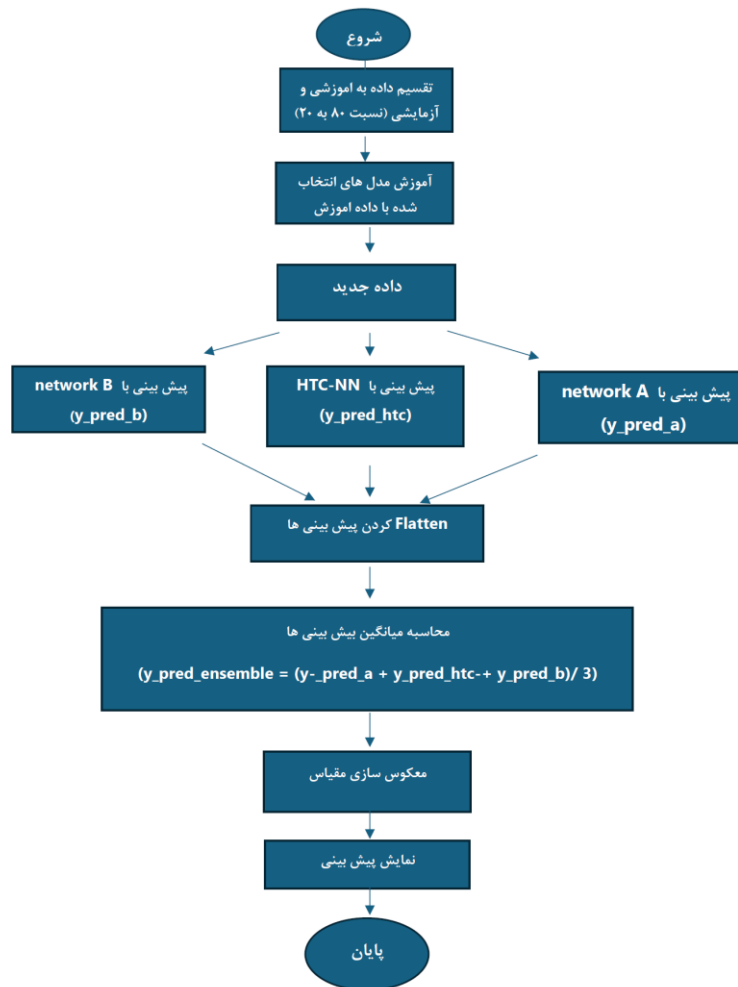
جدول ۳- پارامترهای آموزش مدل‌ها.

Hyperparameter	Value	Description
Optimizer	Adam	Adaptive Optimizer
Learning Rate	0.001	Default Keras Value for Adam
Loss Function	Mean Squared Error (MSE)	Standard Loss Function for Regression
Batch Size	32	Input Batch Size
Epochs	100	Number of Training Epochs

فلوچارت مراحل مختلف آموزش مدل‌ها و ارزشیابی روش پیشنهادی Ensemble، شامل مراحل آماده‌سازی داده‌ها، ایجاد توالی‌های زمانی، آموزش مدل‌های جداگانه (مانند Network A، HTC-NN و Network B)، و ترکیب پیش‌بینی‌ها برای بهینه‌سازی دقت، در شکل ۱ نشان داده شده است.

^۱epoch

^۲flattening

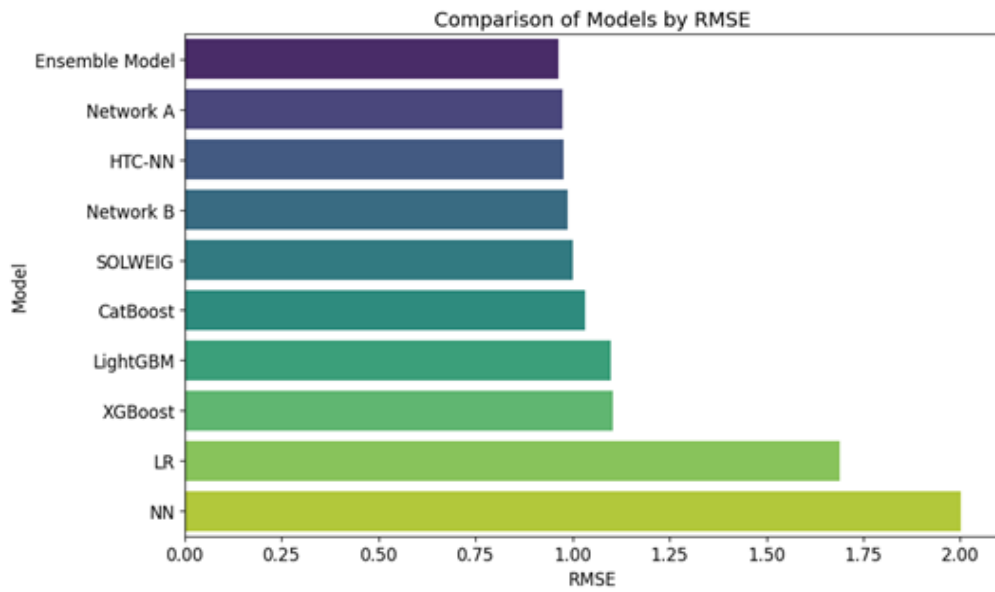


شکل ۱- فلوچارت روش پیشنهادی برای آموزش مدل های پیش بینی و ارزیابی روش ترکیبی.

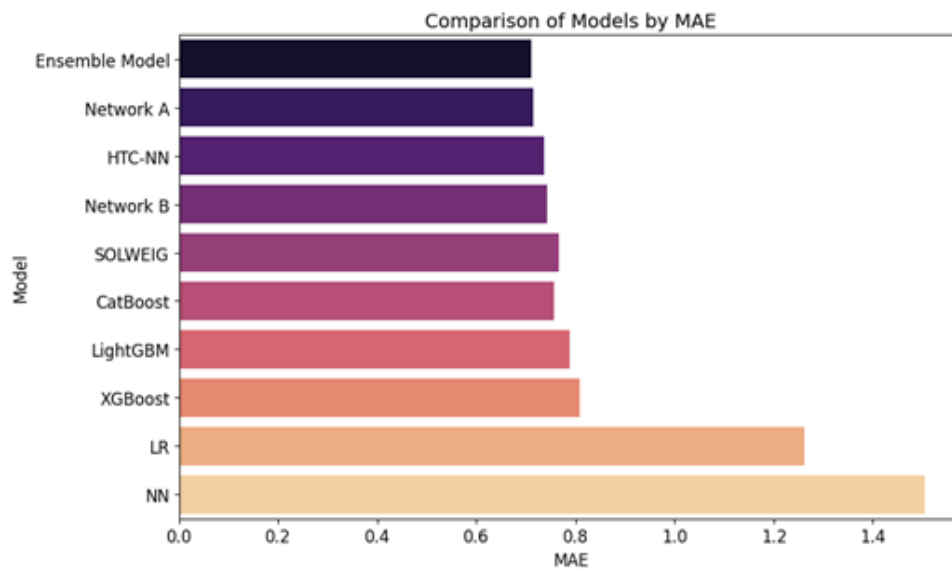
برای ارزیابی روش پیشنهادی از سه معیار استاندارد RMSE، MAE و R^2 بهره گرفته شد. پیش بینی ها و مقادیر واقعی با استفاده از نرمال ساز `utci_scaler` به مقیاس اصلی بازگردانده شدند تا نتایج قابل تفسیر باشند. شکل های ۲، ۳ و ۴ به ترتیب عملکرد مدل های مختلف را بر اساس معیار RMSE (ریشه میانگین مربعات خطا)، معیار MAE و معیار R^2 نشان می دهند.

در شکل ۲، مدل ترکیبی پیشنهادی (Ensemble Model) با کمترین مقدار RMSE به عنوان برجسته ترین گزینه ظاهر شده است، که نشان دهنده توانایی بالای این مدل در کاهش خطای پیش بینی و تطابق خوب با داده های واقعی است. این نتیجه ناشی از ترکیب چندین الگوریتم در این مدل می باشد که نقاط قوت هر یک را تقویت کرده است.

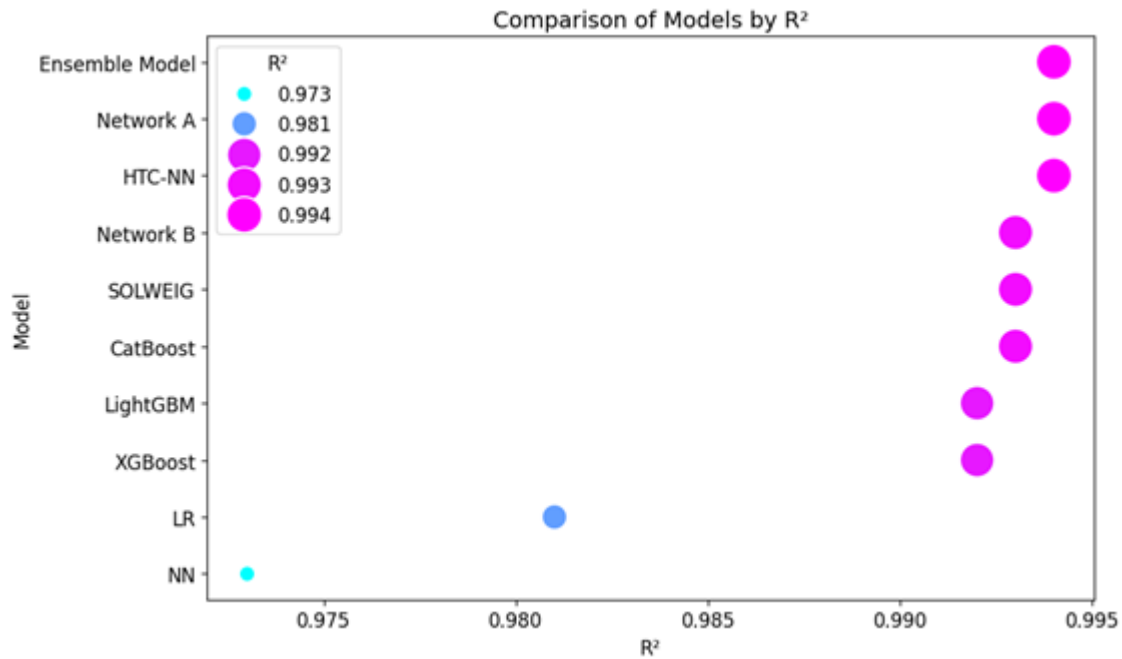
در شکل ۳، مدل ترکیبی پیشنهادی کمترین مقدار MAE را داشته است. این نتیجه نشان دهنده توانایی این مدل در ارائه پیش بینی هایی با خطای متوسط پایین است، که می تواند به دلیل ترکیب بهینه چندین روش پیش بینی باشد. این موضوع اهمیت رویکردهای ترکیبی را در بهبود دقت مدل ها برجسته می کند. شکل ۴ نیز عملکرد بهتر مدل پیشنهادی بر اساس معیار ضریب تعیین را نشان می دهد که بیان کننده میزان تطبیق مقادیر پیش بینی و مقادیر واقعی می باشد.



شکل ۲- مقایسه مدل‌های مختلف بر اساس معیار RMSE.



شکل ۳- مقایسه مدل‌های مختلف بر اساس معیار MAE.



شکل ۴- مقایسه مدل‌های مختلف بر اساس معیار R^2 .

جدول ۴ روش ترکیبی را با سایر روش‌های ترکیبی مقایسه می‌کند.

جدول ۴- مقایسه روش پیشنهادی با روش‌های ترکیبی دیگر

Model Architecture	Training Data Source	Test City	RMSE	MAE	R^2
Ensemble Model	Trained on Combined (Mashhad + Tabriz) Data	Tabriz	0.921	0.697	0.994
Ensemble Model	Trained on Combined (Mashhad + Tabriz) Data	Mashhad	0.926	0.694	0.994
Ensemble Model	Trained on Tabriz Data Only	Tabriz	0.941	0.724	0.994
Ensemble Model	Trained on Mashhad Data Only	Mashhad	0.963	0.71	0.994
CNN+LSTM	Trained on Tabriz Data Only	Tabriz	1.025	0.777	0.992
CNN+LSTM	Trained on Combined (Mashhad + Tabriz) Data	Tabriz	1.026	0.788	0.992
CNN+LSTM	Trained on Combined (Mashhad + Tabriz) Data	Mashhad	1.027	0.793	0.993
CNN+LSTM	Trained on Mashhad Data Only	Mashhad	1.095	0.863	0.992
GNN	Trained on Combined (Mashhad + Tabriz) Data	Mashhad	2.88	2.157	0.944
GNN	Trained on Combined (Mashhad + Tabriz) Data	Tabriz	3.189	2.361	0.927

مدل ترکیبی^۱ به دو دلیل کلیدی توانست از معماری‌های پیچیده‌تر زمانی (CNN+LSTM) و مکانی-زمانی (GNN) عملکرد

بهتری داشته باشد:

^۱Ensemble

^۲Graph Neural Network

- ماهیت مسئله: شاخص $UTCI$ ، با وجود پیچیدگی، یک تابع معین از متغیرهای هواشناسی ورودی (دما، رطوبت، سرعت باد و تابش) است. یک شبکه MLP ، به عنوان یک تقریب‌زننده ذاتاً برای یادگیری چنین روابط تابعی پیچیده و غیرخطی مناسب است. در مقابل، مدل‌های $CNN+LSTM$ برای کشف الگوهای زمانی پیچیده طراحی شده‌اند که ممکن است در این مسئله‌ی پیش‌بینی تک-گامی^۱، اهمیت ثانویه داشته باشند. به نظر می‌رسد مدل MLP توانسته است به شکل مستقیم‌تری، وزن بهینه را به هر ورودی در بازه زمانی ۱۲ ساعته اختصاص دهد.
- قدرت رویکرد ترکیبی: با میانگین‌گیری از خروجی سه مدل آموزش دیده، مدل نهایی از بایاس کمتر و پایداری بیشتری برخوردار شده است. این کار گروهی باعث می‌شود خطاهای جزئی هر مدل پوشش داده شود و نتیجه نهایی قابل اعتمادتر باشد. همچنین مدل GNN با اختلاف قابل توجهی ضعیف‌ترین عملکرد را داشت. دلیل اصلی این امر، عدم وجود یک ساختار گراف غنی و معنادار در مسئله ماست. شبکه‌های عصبی گراف، قدرت خود را از توپولوژی گراف (نحوه اتصال نودها) می‌گیرند. در این پژوهش، گراف ما تنها شامل دو نود (مشهد و تبریز) با یک یال ساده بود. این ساختار، اطلاعات مکانی کافی برای یادگیری الگوهای پیچیده را در اختیار مدل GNN قرار نمی‌دهد و پیچیدگی بالای خود مدل در این شرایط ساده، منجر به یادگیری ضعیف شده است. این یافته نشان می‌دهد که انتخاب معماری باید متناسب با ساختار ذاتی داده‌ها باشد.

۴- نتیجه‌گیری

این پژوهش به دلیل اهمیت آسایش حرارتی در فضاهای باز شهری بر سلامت و رضایت شهروندان و نیاز به پیش‌بینی دقیق آسایش حرارتی و شرایط حرارتی محیطی در مناطق شهری به منظور بهبود برنامه‌ریزی شهری و مدیریت انرژی انجام شد. روشهای مختلفی در ارزیابی آسایش حرارتی وجود دارد که شاخص جهانی اقلیم حرارتی نسبت به تغییرات زمانی در عناصر جوی از سایر شاخص‌های آسایش حساس‌تر است. ضمن اینکه با بسیاری از شاخص‌های آسایش حرارتی وابستگی زیادی دارد. این پژوهش با هدف پیش‌بینی دقیق شاخص آسایش حرارتی جهانی با استفاده از داده‌های هواشناسی شهر مشهد و تبریز و بهره‌گیری از روش‌های یادگیری عمیق و ترکیبی انجام شد. مدل پیشنهادی روش ترکیبی که با ترکیب سه مدل شبکه عصبی طراحی شد، با استفاده از یک پنجره زمانی ۱۲ ساعته و نرمال‌سازی داده‌ها، توانست الگوهای غیرخطی و دوره‌ای موجود در متغیرهای هواشناسی (دمای هوا، رطوبت نسبی، سرعت باد، و تابش خورشیدی) را با دقت بالایی مدل‌سازی کند. نتایج ارزیابی نشان داد که مدل ترکیبی با بهتری با مقادیر $RMSE=0.963$ ، $MAE=0.711$ و $R^2=0.994$ عملکرد قابل‌قبولی در پیش‌بینی $UTCI$ ارائه داد. این نتایج نشان‌دهنده برتری روش ترکیبی در کاهش خطای پیش‌بینی و بهبود تعمیم‌پذیری نسبت به مدل‌های منفرد است. یافته‌های این مطالعه اهمیت قابل توجهی در پیش‌بینی شرایط آسایش حرارتی در فضای باز مناطق شهری دارند. دقت بالای مدل پیشنهادی، امکان پیش‌بینی دقیق‌تر شاخص $UTCI$ را فراهم می‌کند که می‌تواند در برنامه‌ریزی شهری، مدیریت منابع انرژی، و بهبود کیفیت زندگی ساکنان مناطق مختلف متناسب با اقلیم منطقه مورد استفاده قرار گیرد.

تحلیل ماتریس همبستگی نشان داد که دمای هوا و رطوبت نسبی تأثیرات کلیدی بر $UTCI$ دارند، در حالی که تابش خورشیدی و سرعت باد نقش‌های کمتری ایفا می‌کنند. این بینش‌ها می‌توانند به سیاست‌گذاران و مهندسان در طراحی سیستم‌های تهویه و خنک‌کننده کارآمدتر کمک کنند. با این حال، محدودیت‌هایی نظیر فرض برابر بودن دمای تابشی با دمای هوا و حذف ۵٪ از داده‌ها به دلیل مقادیر نامعتبر، ممکن است بر دقت پیش‌بینی‌ها در شرایط خاص تأثیر گذاشته باشد. برای توسعه این پژوهش، پیشنهاد می‌شود که در مطالعات آتی، دمای تابشی به صورت مستقیم از داده‌های حسگرهای پیشرفته یا مدل‌های شبیه‌سازی محاسبه شود تا دقت محاسبات $UTCI$ بهبود یابد.

در این پژوهش از داده‌های هواشناسی ماهواره‌ای $Solcast$ استفاده شد که یکی از منابع پیشرو در این حوزه است. با این حال، این نوع داده‌ها ذاتاً با محدودیت‌هایی همراه هستند. داده‌های ماهواره‌ای، نماینده میانگین شرایط آب‌وهوایی در یک سلول شبکه‌ای (مثلاً با

^۱one-step-ahead

^۲bias

ابعاد ۱*۱ کیلومتر) هستند. این رویکرد قادر به ثبت تغییرات اقلیمی در مقیاس خرد^۱ نیست. برای مثال، اثر سایه‌اندازی یک ساختمان بلند یا تأثیر یک پارک کوچک در دمای یک نقطه خاص از شهر در این داده‌ها لحاظ نمی‌شود. در مقابل، ایستگاه‌های زمینی داده‌های نقطه‌ای و دقیق‌تری ارائه می‌دهند، هرچند پوشش مکانی آن‌ها محدود است همچنین داده‌های Solcast حاصل اندازه‌گیری مستقیم زمینی نیستند، بلکه خروجی مدل‌های پیچیده‌ای هستند که تصاویر ماهواره‌ای را تحلیل می‌کنند. اگرچه این مدل‌ها بسیار دقیق هستند، اما همچنان یک تخمین محسوب شده و ممکن است در شرایط جوی پیچیده (مانند پوشش ابرهای پراکنده) دارای عدم قطعیت‌هایی در مقایسه با سنسورهای فیزیکی کالیبره شده باشند.

در نهایت برای گسترش و بهبود نتایج این پژوهش، به عنوان یک مسیر پژوهشی بسیار امیدوارکننده، می‌توان از معماری Transformer بهره برد. این مدل‌ها با استفاده از مکانیزم توجه^۲ قادرند به صورت هوشمندانه اهمیت گام‌های زمانی مختلف را در پیش‌بینی بسنجند. برای مثال، یک مدل Transformer ممکن است یاد بگیرد که برای پیش‌بینی دمای ساعت بعد، اطلاعات مربوط به ۲۴ ساعت قبل (همین ساعت در روز گذشته) اهمیت بیشتری نسبت به اطلاعات ۱۲ ساعت قبل دارد. این قابلیت می‌تواند به پیش‌بینی‌های دقیق‌تر، به‌ویژه برای افق‌های زمانی طولانی‌تر، منجر شود. همچنین برای افزایش دقت پیش‌بینی‌ها در محیط‌های شهری پیچیده، می‌توان داده‌های هواشناسی را با منابع داده‌ای دیگر مانند داده‌های مورفولوژی شهری (ارتفاع ساختمان‌ها، درصد فضای سبز) یا داده‌های آلودگی هوا (غلظت آلاینده‌ها) ترکیب کرد. این رویکرد می‌تواند به مدل درک بهتری از عوامل مؤثر بر آسایش حرارتی در مقیاس شهری بدهد.

در مجموع، این پژوهش با ارائه یک روش ترکیبی مبتنی بر یادگیری عمیق، گامی مؤثر در جهت پیش‌بینی دقیق شاخص UTCI برداشت. نتایج حاصل نه تنها به درک بهتر عوامل مؤثر بر آسایش حرارتی کمک می‌کند، بلکه به برنامه ریزان و مدیران شهری کمک می‌کند که بتوانند در برنامه ریزی دقیق‌تر و طولانی مدت در حوزه‌های شهری و انرژی از این نتایج بهره ببرند. این مطالعه زمینه‌ساز تحقیقات آینده در جهت بهبود مدل‌های پیش‌بینی مبتنی بر هوش مصنوعی در حوزه هواشناسی خواهد بود.

۵- منابع

- Galal, O. M.; Sailor, D. J.; Mahmoud, H. The impact of urban form on outdoor thermal comfort in hot arid environments during daylight hours, case study: New Aswan. *Building and Environment*. 2020;184:107222. DOI: [10.1016/j.buildenv.2020.107222](https://doi.org/10.1016/j.buildenv.2020.107222)
- Jia, S.; et al. A hybrid framework for assessing outdoor thermal comfort in large-scale urban environments. *Landscape and Urban Planning*. 2025;256:105281. DOI: [10.1016/j.landurbplan.2024.105281](https://doi.org/10.1016/j.landurbplan.2024.105281)
- Jing, W.; et al. Evaluating thermal comfort indices for outdoor spaces on a university campus. *Scientific Reports*. 2024;14(1):21253. DOI: [10.1038/s41598-024-71805-5](https://doi.org/10.1038/s41598-024-71805-5)
- Hataminejad, H.; Arvin, M.; Mohammadivanani, A.; Bzrafkan, S. Analysis of the spatial crimes dispersion in urban parks (case study: Parks Tehran city). *Strategic Research on Social Problems*. 2017;6(2):89-104. DOI: [10.22108/ssoss.2017.22146](https://doi.org/10.22108/ssoss.2017.22146)
- Ahmadi, M.; Dadashi, A. The Identification of Urban Thermal Islands based on an Environmental Approach, Case Study: Isfahan Province. *Geography and Environmental Planning*. 2017;28(3):1-20. DOI: [10.22108/gep.2017.98318.0](https://doi.org/10.22108/gep.2017.98318.0)

^۱microclimate

^۲Attention Mechanism

6. Megri, A. C.; El Naqa, I. Prediction of the thermal comfort indices using improved support vector machine classifiers and nonlinear kernel functions. *Indoor and Built Environment*. 2014;25(1):6-16. DOI: [10.1177/1420326X14539693](https://doi.org/10.1177/1420326X14539693)
7. Veisi, O.; Attarhay Tehrani, A.; Gharaei, B.; Shakibamanesh, A. Using Artificial Intelligence for Predicting Universal Thermal Climate Index Based on Different Urban Conditions: A Comparative Study of Machine Learning Models. SSRN. DOI: [10.2139/ssrn.4840700](https://doi.org/10.2139/ssrn.4840700)
8. Kuzmanović, D.; Banko, J.; Skok, G. Improving the operational forecasts of outdoor Universal Thermal Climate Index with post-processing. *International Journal of Biometeorology*. 2024;68(5):965–977. DOI: [10.1007/s00484-024-02640-6](https://doi.org/10.1007/s00484-024-02640-6)
9. Shah, R.; Pandit, R.; Gaur, M. Urban physics and outdoor thermal comfort for sustainable street canyons using ANN models for composite climate. *Alexandria Engineering Journal*. 2022;61(12):10871–10896. DOI: [10.1016/j.aej.2022.04.024](https://doi.org/10.1016/j.aej.2022.04.024)
10. Briegel, F.; et al. High-resolution multi-scaling of outdoor human thermal comfort and its intra-urban variability based on machine learning. *Geoscientific Model Development*. 2024;17(4):1667–1688. DOI: [10.5194/gmd-17-1667-2024](https://doi.org/10.5194/gmd-17-1667-2024)
11. Yang, Z.; et al. GloUTCI-M: a global monthly 1 km Universal Thermal Climate Index dataset from 2000 to 2022. *Earth System Science Data*. 2024;16(5):2407–2424. DOI: [10.5194/essd-16-2407-2024](https://doi.org/10.5194/essd-16-2407-2024)
12. Zhong, G. Convolutional Neural Network Model to Predict Outdoor Comfort UTCI Microclimate Map. *Atmosphere*. 2022;13(11):1860. DOI: [10.3390/atmos13111860](https://doi.org/10.3390/atmos13111860)
13. Liu, T.; et al. Outdoor Thermal Comfort Research and Its Implications for Landscape Architecture: A Systematic Review. *Sustainability*. 2025;17(5):2330. DOI: [10.3390/su17052330](https://doi.org/10.3390/su17052330)
14. Anders, J.; et al. Simplifying heat stress assessment: Evaluating meteorological variables as single indicators of outdoor thermal comfort in urban environments. *Building and Environment*. 2025;274:112658. DOI: [10.1016/j.buildenv.2025.112658](https://doi.org/10.1016/j.buildenv.2025.112658)
15. Ahmadi, M. M.; Amini Zadeh, B.; Aqamalai, R. Thermal performance assessment of urban fabric in Tehran climate: lessons for climate-responsive urban design. *Journal of Fine Arts: Architecture and Urbanism*. 2020;25(1):5–15. DOI: [10.22059/jfaup.2020.296175.672397](https://doi.org/10.22059/jfaup.2020.296175.672397)
16. Lee, H.; Park, S.; Mayer, H. Approach for the vertical wind speed profile implemented in the UTCI basics blocks UTCI applications at the urban pedestrian level. *International Journal of Biometeorology*. 2025;69(3):567–580. DOI: [10.1007/s00484-025-02915-6](https://doi.org/10.1007/s00484-025-02915-6)
17. Entezari, A.; Mayvaneh, F.; Rezaie, K.; Rahimi, F. An adaptive estimation method to predict thermal comfort indices using deep belief neural networks. *Journal of Geographic Sciences (JGS)*. 2018;18(51):23–40. DOI: [10.29252/jgs.18.51.23](https://doi.org/10.29252/jgs.18.51.23)
18. Solcast. Available from: <https://solcast.com/>.
19. Palma, W. *Time Series Analysis*. John Wiley & Sons; 2016.
20. Han, J.; Kamber, M.; Pei, J. *Data Mining: Concepts and Techniques*. Waltham: Morgan Kaufmann Publishers; 2012.