

یک مدل پیش‌بینی آسایش حرارتی جدید مبتنی بر یادگیری عمیق با استفاده از پارامترهای محیطی و شخصی

اعظم نوروزی*

استادیار، گروه عمران و معماری، دانشکده فنی و مهندسی، دانشگاه تربت حیدریه، تربت حیدریه، ایران

پست الکترونیکی: a.noroozi@torbath.ac.ir

حسین غلامعلی نژاد

استادیار، گروه کامپیوتر، دانشگاه بزرگمهر قاینات، قاین، ایران

پست الکترونیکی: h_gholamalinejad@buqaen.ac.ir

چکیده

ویژگی، این مطالعه ابتدا ماتریس همبستگی به‌دست‌آمده از داده‌های اشری ۱ را محاسبه و تجزیه و تحلیل کرد که منجر به انتخاب چهار پارامتر محیطی (دمای هوا، میزان رطوبت، متوسط دمای تابشی، سرعت هوا) و دو عامل شخصی نرخ پوشش و نرخ فعالیت متابولیکی شد. سپس، یک مدل پیش‌بینی سطح آسایش حرارتی با تکنیک مبتنی بر یادگیری عمیق توسعه داده شد. نتایج ارزیابی بر اساس مجموعه داده‌های اشری نشان داد که مدل پیشنهادی در تمام معیارهای پیش‌بینی بهتر از روش‌های یادگیری ماشین مرسوم عمل می‌کند.

کلید واژه‌ها: آسایش حرارتی، یادگیری عمیق، بهینه‌سازی مصرف انرژی، پارامترهای حرارتی محیطی.

۱- مقدمه

در قرن اخیر، استفاده از سوخت‌های فسیلی و نگرانی‌های زیست‌محیطی ناشی از آنها از جمله

ساختمان‌ها ۳۰ درصد از کل دی اکسید کربن منتشر شده از مصرف انرژی را تولید می‌کنند. طراحی ساختمان با کمترین تلفات انرژی و تأمین آسایش حرارتی فضاهای داخلی با حداقل مصرف انرژی، روشی مؤثر برای کاهش مصرف انرژی است. پیشرفت‌های اخیر در هوش مصنوعی تخمین دقیقی از سطح آسایش حرارتی ساختمان‌ها ارائه می‌دهد که به طور قابل توجهی بر عملکرد سیستم‌های کنترل هوشمند و بهینه‌سازی ساختمان‌ها تأثیر می‌گذارد. روش‌های مبتنی بر یادگیری عمیق، بهبود عملکرد قابل توجهی را در پیش‌بینی آسایش حرارتی نشان داده‌اند. این مقاله یک مدل مبتنی بر یادگیری عمیق ارائه می‌دهد که سطح آسایش حرارتی یک ساختمان را با استفاده از عوامل محیطی و شخصی پیش‌بینی می‌کند. انتخاب ویژگی یک مرحله ضروری در یادگیری ماشین است که می‌تواند دقت را افزایش دهد. بنابراین، برای مرحله انتخاب

در بخش بعد کارهای پیشین مرتبط با مقاله ارائه می‌گردد. سپس روش پیشنهادی معرفی می‌گردد. در بخش ۴ نتایج و در پایان نتیجه گیری مقاله ارائه می‌شود.

۲- کارهای پیشین

آسایش حرارتی توسط انجمن مهندسان گرمایش، سرمایش و تهویه مطبوع آمریکا^۱ به عنوان «وضعیت ذهنی که رضایت از محیط حرارتی را ابراز می‌کند و با ارزیابی ذهنی ارزیابی می‌شود» تعریف شده است. شرایط حرارتی در ساختمان‌ها بر بهره‌وری و کیفیت زندگی ساکنان تأثیر می‌گذارد. همچنین تأثیر زیادی بر مصرف انرژی ساختمان دارد. بنابراین، ارزیابی دقیق آسایش حرارتی ساکنان برای حفظ یک محیط حرارتی راحت و در عین حال صرفه‌جویی در مصرف انرژی ضروری است.

تا به امروز، پرکاربردترین مدل در پیش‌بینی آسایش حرارتی، مدل میانگین رأی پیش‌بینی شده^۲ است که بر اساس مدل‌سازی تعادل حرارتی حالت پایدار ارائه شده توسط فنگر در دهه ۱۹۷۰ بنا شده است. طبق مدل میانگین رأی پیش‌بینی شده، احساس حرارتی ساکنان در ساختمان‌ها را می‌توان با چهار پارامتر محیطی دمای هوا، رطوبت نسبی، میانگین دمای تابشی و سرعت هوا، و همچنین دو پارامتر شخصی عایق لباس و میزان متابولیسم فعالیت تعیین کرد. از زمان معرفی مدل میانگین رأی پیش‌بینی شده، بسیاری از محققان در سراسر جهان سعی کرده‌اند اثربخشی آن را با استفاده از آزمایش‌های محفظه آب و هوا یا مطالعات میدانی تأیید کنند. به طور کلی پیشنهاد می‌شود که مدل میانگین رأی پیش‌بینی شده در تخمین احساس حرارتی در ساختمان‌های ساکن و دارای تهویه مطبوع مؤثر است، اما در ساختمان‌های دارای تهویه طبیعی چندان خوب نیست. در ادامه کارهای انجام شده در این حوزه شامل مدل‌های سنتی و مدل‌های مبتنی بر یادگیری ماشین مورد بررسی قرار می‌دهیم.

چالش برانگیزترین مسائل بوده‌اند. این موضوع، نیاز مبرم به ایجاد راه‌حلی در بسیاری از بخش‌ها برای پاسخ به نگرانی‌های انرژی را آشکار می‌کند. حدود ۳۰ درصد از انتشار جهانی دی‌اکسیدکربن ناشی از مصرف انرژی ساختمان‌ها است که موضوعی چالش برانگیز است. بهینه‌سازی مصرف انرژی در این بخش می‌تواند راه‌حلی برای کاهش مصرف انرژی جهانی باشد [۱]. بحث‌های فزاینده‌ای در مورد امکان‌سنجی ساخت ساختمان‌های انرژی صفر وجود دارد [۲]. اما این موارد در مرحله اولیه اجرا هستند [۳]. بهترین راه‌حل پیشنهادی تاکنون، طراحی ساختمان‌هایی با کمترین اتلاف انرژی و تأمین دمای صفر فضای داخلی با حداقل مصرف انرژی است [۴]. تنظیم دمای بدن انسان با پاسخ‌های غیرارادی و ارادی محاسبه می‌شود. دمای صفر نشان‌دهنده رضایت از محیط است که می‌توان آن را با استفاده از شاخص‌ها و حس دما اندازه‌گیری کرد.

پیشرفت‌های اخیر در روش‌های جمع‌آوری و تحلیل داده‌های هوش مصنوعی نشان داده است که می‌تواند با پیش‌بینی سطوح آسایش حرارتی در ساختمان‌ها نقش مهمی در بهینه‌سازی مصرف انرژی ایفا کند. هوش مصنوعی توانایی کامپیوتر در اعمال ویژگی‌های هوشمندانه و شبیه به انسان می‌باشد. این توانایی کاربردهای زیادی در زمینه‌های مختلف دارد. به عنوان مثال، هوش مصنوعی در پزشکی [۵]، بخش بازی [۶]، محاسبات عمومی و غیره استفاده شده است. تخصص هوش مصنوعی، تجزیه و تحلیل داده‌های تاریخی برای ساخت یک مدل پیش‌بینی است. این مدل‌ها برای آموزش ماشین‌ها به منظور استدلال مانند انسان و سپس پیش‌بینی رویدادهای خاص یا رویدادهای آینده استفاده می‌شوند.

پیش‌بینی دقیق آسایش حرارتی از جمله چالش‌های این حوزه می‌باشد. این مقاله سعی کرده است با ارائه یک ساختار توسعه یافته مبتنی بر یادگیری عمیق دقت پیش‌بینی را بهبود بخشد. ادامه مقاله شامل بخش‌های زیر می‌باشد.

۲-۱- مدل‌های سنتی آسایش حرارتی

از دیدگاه فیزیولوژیکی، مطالعات بلاگدن در مورد استفاده از دماسنج در یک اتاق گرم، تلاش‌های اولیه برای درک سیستم حرارتی بدن انسان است [۷]. تحقیقات او توانایی افراد در تحمل دماهای بالا را نشان داده است. ریچت تنظیمات سیستم مغز انسان را در درک گرما کشف کرد [۸]. گاک بر مطالعه فرآیند گرما در بدن انسان تمرکز کرد و او یک رویکرد تعادل حرارتی برای شناسایی سطح آسایش حرارتی با استفاده از مجموعه داده‌های اشری معرفی کرد [۹].

مطالعه آسایش حرارتی از قرن بیستم، زمانی که معرفی سیستم‌های تهویه مطبوع مدل‌های ساده‌ای از تعامل دو جزء را شکل داد، توسعه بیشتری یافته است. گیوونی [۱۰] و فانگر [۱۱] با ارائه مدل تنش حرارتی و میانگین رأی پیش‌بینی شده، مطالعات را ادامه دادند. مدل میانگین رأی پیش‌بینی شده در اتاق‌های اقلیمی، با استفاده از بسیاری از شرکت‌کنندگان که لباس‌های استاندارد پوشیده بودند و فعالیت‌های کاملاً استاندارد را در محیط‌های حرارتی مختلف انجام می‌دادند، انجام شد. چندین تحقیق تلاش کرده‌اند تا با مطالعه محیط‌های محفظه اقلیمی یا مطالعات میدانی، این مدل را اعتبارسنجی کنند [۱۲، ۱۳].

دیر و همکارانش یک مدل تطبیقی [۱۴] توسعه دادند که در آن ساکنین هر بار با دمای متفاوت سازگار می‌شوند. علاوه بر این، راحتی آنها را می‌توان با تغییر عوامل شخصی مانند لباس یا باز یا بسته کردن پنجره به دست آورد. جین و همکارانش [۱۵] بررسی کردند که چگونه فناوری‌های جدید محاسبات فراگیر می‌توانند از آسایش حرارتی تطبیقی پشتیبانی کنند.

رویکردهای تخمین و مدل‌سازی آسایش حرارتی از روش‌های آماری مرسوم برای یافتن سطوح و پارامترهای آسایش حرارتی استفاده می‌کنند. روش‌های آماری مرسوم به تجزیه و تحلیل نسبت‌های پیچیده، مانند تعامل ساکنین با محیط، محدود هستند که ممکن است دلیل نادقیق

بودن آنها باشد [۱۶]. در مجموع، می‌توان نتیجه گرفت که مدل‌های بیان شده در اندازه‌گیری آسایش حرارتی، توانایی توصیف دقیق شرایط متغیر آسایش حرارتی در فضاهای داخلی و خارجی را ندارند.

۲-۲- مدل‌های مبتنی بر یادگیری ماشین

اخیراً، الگوریتم‌های یادگیری ماشین به دلیل توانایی‌های عالی خودآموزی و همچنین توانایی سریع در یافتن راه‌حل‌های بهینه، برای حل مسائل پیچیده غیرخطی مورد استفاده قرار گرفته‌اند.

هو و همکاران [۱۸] آسایش حرارتی ساکنین را با تصویربرداری حرارتی کم‌هزینه پیش‌بینی کردند. به همین ترتیب، ژانگ و همکاران [۱۹] دمای هوای داخلی را با استفاده از ترموگرافی مادون قرمز صورت و یک مدل مارکوف تخمین زدند. رن و همکاران [۲۰] مدلی را با استفاده از سیگنال‌های فیزیولوژیکی جنسیت‌های مختلف و یک مدل مبتنی بر جنگل تصادفی پیشنهاد کردند. مشکل همه مدل‌های ذکر شده این است که تجهیزات اضافی، مانند عینک‌های هوشمند، باید نصب شوند.

چندین مدل پیش‌بینی از الگوریتم‌های یادگیری ماشین برای افزایش قابلیت‌ها در محدوده‌های مختلف استفاده کرده‌اند [۲۱]. تحقیقات اخیر عمدتاً روش‌هایی مبتنی بر شبکه‌های عصبی و درخت‌های تصمیم‌گیری را برای تخمین سطح آسایش حرارتی داخلی یا بهبود شاخص‌های مدل‌های موجود پیشنهاد کرده‌اند. علاوه بر این، مدل‌هایی مانند ماشین بردار پشتیبان به طور گسترده از تکنیک‌های یادگیری نمونه برای تخمین سطح آسایش حرارتی داخلی استفاده کرده‌اند. برخی مطالعات با استفاده از روش‌های یادگیری ماشین در پیش‌بینی آسایش حرارتی، دمای هوای داخلی را بر اساس سایر ویژگی‌ها تخمین زده‌اند تا محیط داخلی را به صورت پیشگیرانه کنترل کنند. تحقیقات دیگر مدل‌ها را با استفاده از متغیرهای مختلف برای پیش‌بینی دمای هوای داخلی آموزش داده‌اند [۲۲-۲۴].

۳-۱- مجموعه داده

برای ارزیابی مدل پیشنهادی، از پایگاه داده جهانی آسایش حرارتی اشریه استفاده شد. این مجموعه داده‌ها، یک پروژه همکاری بود که توسط دانشگاه‌های کالیفرنیا و سیدنی برای ارزیابی تحقیقات آسایش حرارتی مدیریت می‌شد [۳۱]. چندین معیار در انتخاب اطلاعات برای توسعه پایگاه داده مورد استفاده قرار گرفت. اولین معیار این است که داده‌ها باید از آزمایش‌های میدانی به جای آزمایش‌های فضای آزمایشگاهی به دست آیند. علاوه بر این، ملاحظات مربوط به اجزای شرایط فیزیکی داخل و ارزیابی‌های ذهنی باید به طور هم زمان در یک مکان خاص انجام شود. همچنین، داده‌ها باید به صورت خام و پردازش نشده ارائه شوند. در حال حاضر، ۸۱۸۴۶ رکورد از ۵۲ حوزه تحقیقاتی از ۱۶۰ ساختمان در پایگاه داده موجود است و این اطلاعات به صورت رایگان در دسترس افراد قرار دارد. پایگاه داده جهانی آسایش حرارتی اشری، ۶۸ ویژگی را ثبت کرده است که رتبه‌بندی‌های ذهنی آسایش حرارتی، اندازه‌گیری‌های فیزیکی عینی، ویژگی‌های ساختمان، ویژگی‌های ساکنین ساختمان، شرایط آب و هوایی و آب و هوای منطقه‌ای را پوشش می‌دهد. این تحقیقات در ۲۸ کشور انجام شده است.

۳-۲- ماتریس همبستگی

برای این که نشان دهیم پارامترهای فنگر در این مجموعه داده نیز بیشترین اهمیت را در پیش‌بینی آسایش حرارتی دارند ماتریس همبستگی آنها بر اساس داده‌ها رسم شد.

شکل ۱ ماتریس همبستگی متغیرهای مختلف محیطی و شخصی را نشان می‌دهد. هر سلول ضریب همبستگی متغیرها را نشان می‌دهد که بین ۱ و -۱ متغیر است.

موارد زیر در ماتریس همبستگی وجود دارد:

- Clo همبستگی ضعیفی با سایر متغیرها، به ویژه همبستگی منفی با $AT (-0.42)$ و $RT (-0.30)$ دارد.

مزیت اساسی الگوریتم یادگیری ماشین، توانایی آنها در تخمین دقیق عناصر هدف با استفاده از متغیرهای ورودی است که هزینه و زمان مدل‌سازی آسایش حرارتی را کاهش می‌دهد. فرهان و همکارانش [۲۵] مدلی را بر اساس روش ماشین بردار پشتیبان و مؤلفه‌های محیطی، رفتاری و فیزیولوژیکی پیشنهاد کردند. دقت آن در مقایسه با روش استاندارد میانگین رأی پیش‌بینی شده $(35/4\%)$ برابر $76/7\%$ درصد بود. بین و کی [۲۶] شاخص میانگین رأی پیش‌بینی‌شده را با توجه به شش عامل فنگر با استفاده از یک مدل مبتنی بر ماشین بردار پشتیبان پیش‌بینی کردند.

آفنبِرگ و همکارانش [۲۹] از شبکه‌های بیزی برای تخمین دمای آسایش فرد استفاده کردند. این مدل $17/5\%$ تا $23/5\%$ درصد دقیق‌تر از شاخص میانگین رأی پیش‌بینی شده بود. دقت آن بر اساس مجموعه داده‌های اشری، 60% درصد بود. به همین ترتیب، قهرمانی و همکارانش [۳۰] یک مدل مبتنی بر شبکه بیزی را با استفاده از داده‌های میدانی شامل ۳۳ نفر برای تخمین ترجیحات حرارتی شخصی بر اساس دمای هوا پیشنهاد کردند. دقت آن 70% درصد و بهتر از مدل مبتنی بر میانگین رأی پیش‌بینی شده (56% درصد) بود.

۳-۳- روش پیشنهادی

روش‌های مختلفی برای پیش‌بینی آسایش حرارتی استفاده می‌شود. جدول ۱ شش پارامتر اساسی و رایج موثر بر آسایش حرارتی را نشان می‌دهد.

جدول ۱: پارامترهای موثر بر آسایش حرارتی

عنوان	توصیف
Clo	میزان پوشش
Met	نرخ فعالیت
AT	دمای هوا
RT	دمای تابشی
RH	میزان رطوبت
AV	سرعت باد
TC	آسایش حرارتی

۳-۳- پیش پردازش داده‌ها

با توجه به این که مقادیر خالی در مجموعه داده وجود داشت قبل از آموزش شبکه این مقادیر بر اساس میانگین و واریانس داده پر شد. ستون‌های غیرضروری حذف شد.

۳-۴- شبکه عصبی پیشنهادی

این ساختار از سه لایه Conv1D با ۳۲ فیلتر و اندازه هسته ۲ استفاده می‌کند (شکل ۲). عنصر دیگر لایه ادغام 1D است. لایه بعدی لایه صاف^۶ است. با استفاده از لایه صاف، ابعاد خروجی برای ورودی به لایه‌های متراکم که شامل ۱۲۸، ۶۴ و ۷ نورون هستند، آماده می‌شوند. در نهایت، یک تابع Softmax به یک لایه خروجی اضافه می‌شود تا خروجی را طبقه‌بندی کند.

۴- ارزیابی

۴-۱- معیارهای ارزیابی


مقایسه خروجی مدل و مقدار واقعی می‌تواند در یکی از دسته‌های زیر قرار گیرد:

- TP نشان می‌دهد که هم پیش‌بینی مدل و هم نمونه واقعی مثبت هستند.
- FP توضیح می‌دهد که پیش‌بینی مدل مثبت است اما نمونه واقعی منفی است.
- TN نشان می‌دهد که پیش‌بینی مدل منفی است و نمونه واقعی نیز منفی است.
- FN نشان می‌دهد که پیش‌بینی مدل منفی است اما نمونه واقعی منفی است.

معادله ۱ صحت را محاسبه می‌کند.

$$Accuracy = \frac{TP+TN}{TN+FN+TP+FP} \quad (1)$$


دقت، عددی را نشان می‌دهد که مدل به درستی پیش‌بینی کرده و در دسته مثبت طبقه‌بندی کرده است (معادله ۲).



شکل ۱: ماتریس همبستگی پارامترها.

- Met و Clo همبستگی مثبت ضعیفی (۰/۰۲) دارند. با این حال، Met و AT همبستگی منفی کمی (۰/۰۷-) دارند.
- AT همبستگی منفی متوسطی با Clo (۰/۴۲-) و همبستگی مثبت با RT (۰/۵۷) دارد.
- RT و AT همبستگی مثبت (۰/۵۷) و در مقایسه با سایر متغیرها ضعیف هستند.
- RH همبستگی ضعیفی با اکثر متغیرها و همبستگی منفی کمی با Clo (۰/۲۴-) نشان می‌دهد.
- AV همبستگی مثبت ضعیفی با AT (۰/۱۴) و TC (۰/۱۲) دارد. TC همبستگی ضعیفی با اکثر متغیرها دارد، که نشان می‌دهد تحت تأثیر عوامل متعددی قرار دارد اما هیچ‌کدام از آنها تأثیر قوی بر آن ندارند.

این ماتریس نشان می‌دهد که دمای هوا و دمای تابشی ارتباط نزدیکی با هم دارند، در حالی که Clo و رطوبت نسبی با چندین متغیر دیگر همبستگی منفی دارند. این روابط نشان می‌دهد که عایق حرارتی لباس و عوامل محیطی در تعیین آسایش حرارتی ضروری هستند.



شکل ۲: شبکه عصبی پیشنهادی.

احتمال برای مسائل طبقه‌بندی است. این الگوریتم پرسرعت و مؤثر برای طبقه‌بندی داده‌ها است.

شکل‌های ۳ تا ۶ عملکرد مراحل آموزش و آزمایش را برای الگوریتم‌های مختلف یادگیری ماشین نشان می‌دهند. برای هر روش (بجز روش پیشنهادی) فرم استاندارد و بهترین نتیجه به‌دست آمده با تغییر پارامترهای در نظر گرفته شده است. جدول ۲ مقادیر پارامترهای استاندارد و تنظیم‌شده هر روش را نشان می‌دهد.

$$Precision = \frac{TP}{TP+FP} \quad (۲)$$

معیار دیگر برای ارزیابی عملکرد مدل، بازخوانی یا حساسیت است. این معیار می‌تواند نسبت نمونه‌های مثبت در دسته مثبت به کل نمونه‌های مثبت را نشان دهد. معادله ۳ بازخوانی را محاسبه می‌کند.

$$Recall = \frac{TP}{TP+FN} \quad (۳)$$

معیار F1-Score ترکیبی از دو معیار قبلی را نشان می‌دهد. معادله ۴ روش محاسبه آن را نشان می‌دهد.


$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (۴)$$

۲-۴- محیط ارزیابی


آزمایش‌ها بر روی یک کامپیوتر شخصی با پردازنده گرافیکی GeForce Turbo RTX-2080 و پردازنده Corei3-9100f با فرکانس ۳۶۰۰ مگاهرتز اجرا شده‌اند. پیاده‌سازی مدل در پایتون ۳.۷ با استفاده از کتابخانه Pytorch انجام شده است. همه آزمایش‌ها در GPU انجام شده است.

۵- نتایج و بحث

چندین الگوریتم مختلف یادگیری ماشین با مدل پیشنهادی مقایسه شدند. یک درخت تصمیم ۷ با تقسیم مجموعه داده‌ها به زیرمجموعه‌هایی بر اساس ویژگی‌ها، یک مدل درخت تصمیم ایجاد می‌کند. یک طبقه‌بندی‌کننده جنگل تصادفی، الگوریتم یادگیری ماشینی است که به طور خاص برای وظایف طبقه‌بندی طراحی شده است. این الگوریتم از چندین درخت تصمیم تصادفی تولید شده استفاده می‌کند و نتایج آنها را برای بهبود دقت پیش‌بینی ترکیب می‌کند. طبقه‌بندی‌کننده XGBoost یک الگوریتم یادگیری ماشین مبتنی بر درخت تصمیم است که در درجه اول برای سرعت و کارایی طراحی شده است. XGBoost با تکنیک تقویت گرادیان، دقت را بهبود می‌بخشد. Naive Bayes یک الگوریتم یادگیری ماشین مبتنی بر نظریه



شکل ۵: مقایسه معیار صحت.




شکل ۶: مقایسه معیار F1-score.

شکل‌های ۳ تا ۶، شبکه عصبی پیشنهادی بالاترین دقت را در آموزش (۹۱/۵۵) و دقت قابل قبولی را در آزمایش (۸۹/۱۹) نشان می‌دهد. دو نسخه از Naive Bayes دقت کمتری دارند، به‌خصوص مدل Naive Bayes که دقت آموزش آن ۰/۷۶۱۷ است. میزان یادآوری در مجموعه آموزش برای اکثر مدل‌ها بالا است که نشان‌دهنده توانایی آنها در شناسایی بسیاری از موارد مثبت واقعی است. با وجود دقت و یادآوری بالا در داده‌های آموزشی، مدل درخت تصمیم در امتیاز F1-score در مجموعه آزمون عملکرد پایین‌تری دارد.

مدل شبکه عصبی پیشنهادی، به‌ویژه در مجموعه آزمون، با معیارهای ذکر شده بهترین عملکرد را دارد. تنظیم مدل‌های جنگل تصادفی و درخت تصمیم منجر به بهبود قابل توجهی نمی‌شود، در حالی که XGBoost و نسخه‌های تنظیم‌شده آن بر اساس معیارها عملکرد نسبتاً خوبی دارند. عملکرد Naive Bayes در مقایسه با سایر مدل‌ها رضایت‌بخش نیست.

جدول ۲: مقادیر پارامترهای استاندارد و تنظیم شده هر روش

مقدار پارامترها	نوع	نام روش
'max_depth': None, 'min_samples_leaf': 1, 'min_samples_split': 2	استاندارد	درخت تصمیم
'max_depth': 8, 'min_samples_leaf': 18, 'min_samples_split': 2	تنظیم شده	
'n_estimators': 100, 'min_samples_split': 2, 'max_depth': None	استاندارد	جنگل تصادفی
'n_estimators': 50, 'min_samples_split': 4, 'max_depth': 14	تنظیم شده	
'n_estimators': 100, 'max_depth': 6, 'learning_rate': 0.3	استاندارد	XGBoost
'n_estimators': 140, 'max_depth': 5, 'learning_rate': 0.26	تنظیم شده	
'var_smoothing': 1e-9	استاندارد	Naive Bayes
'var_smoothing': 0.0533669923120631	تنظیم شده	



شکل ۳: مقایسه معیار دقت.



شکل ۴: مقایسه معیار بازخوانی.

۶- نتیجه‌گیری

حفظ آسایش حرارتی، انرژی قابل توجهی مصرف می‌کند. پیش‌بینی دقیق سطح آسایش حرارتی می‌تواند مصرف انرژی را کاهش دهد. پیشرفت‌های اخیر در جمع‌آوری داده‌های هوش مصنوعی به طور گسترده در صنعت ساختمان برای تخمین آسایش حرارتی و کنترل سطوح آن استفاده می‌شود. این روش‌ها می‌توانند رابطه پیچیده و غیرخطی بین ساکنان و محیط‌های حرارتی آنها را تجزیه و تحلیل کنند. این مقاله با بررسی ماتریس همبستگی ویژگی‌ها، مهم‌ترین ویژگی‌ها را انتخاب کرده و آنها را در اختیار مدل یادگیری عمیق قرار می‌دهد.

مدل پیشنهادی بر اساس پایگاه داده اشری ارزیابی شد. نتایج نشان‌دهنده بالاترین دقت در آموزش (۹۱/۵۵) و دقت قابل قبول در آزمایش (۸۹/۱۹) برای مدل پیشنهادی است. دو نسخه از Naive Bayes نسبت به سایرین، به ویژه مدل بیز ساده که دقت آموزش آن ۷۶۱۷/۰ است، دقت کمتری دارند. میزان یادآوری در مجموعه آموزشی برای اکثر مدل‌ها بالا است که نشان‌دهنده توانایی آنها در شناسایی بسیاری از موارد مثبت واقعی است. با وجود دقت و یادآوری بالا در داده‌های آموزشی، مدل درخت تصمیم در امتیاز F1 در داده‌های آزمون عملکرد پایین‌تری دارد.

علاوه بر این، مقایسه مدل‌های مختلف نشان می‌دهد که اگرچه طبقه‌بندی‌کننده‌های سنتی مانند درخت‌های تصمیم‌گیری و جنگل‌های تصادفی در مرحله آموزش عملکرد خوبی دارند، اما ممکن است به داده‌های دیده نشده به خوبی تعمیم داده نشوند. شبکه عصبی پیشنهادی تقریباً در تمام معیارهای ارزیابی شده نتایج بالایی را نشان می‌دهد که نشان‌دهنده کارایی رویکردهای یادگیری عمیق در حل مسائل طبقه‌بندی است. این تجزیه و تحلیل نشان می‌دهد که معماری‌های عصبی ممکن است ترجیحاً در کاربردهای عملی مورد استفاده قرار گیرند، به خصوص زمانی که هدف دستیابی به دقت و خوانایی بالا در مجموعه داده‌های پیچیده باشد.

سپاسگزاری

این مقاله مستخرج از نتایج طرح تحقیقاتی اجرا شده به شماره ابلاغیه UTH:1402/12/14-215 از محل اعتبارات پژوهشی دانشگاه تربت‌حیدریه می‌باشد که بدین وسیله تشکر و قدردانی می‌گردد.

مراجع

- [1]Meng, L. & Hossain, M. 2013. "Estimation and prediction of residential building energy consumption in rural areas of chongqing," *International Journal of Engineering*, vol. 26, no. 9, pp. 955-962, 2013.
- [2]Hawks, M. & Cho, S. 2024. "Review and analysis of current solutions and trends for zero energy building (ZEB) thermal systems," *Renewable and Sustainable Energy Reviews*, vol. 189, p. 114028, 2024.
- [3]Kayaçetin, N. C. & Hozatlı, B. 2024. "Whole life carbon assessment of representative building typologies for nearly zero energy building definitions," *Journal of Building Engineering*, vol. 95, p. 110214.
- [4]AlizadehKharazi, B., Alvanchi, A. & Taghaddos, H. 2020. "A novel building information modeling-based method for improving cost and energy performance of the building envelope," *International Journal of Engineering*, vol. 33, no. 11, pp. 2162-2173.
- [5]Rajpurkar, P., Chen, E., Banerjee, O. & Topol, E. J. 2022. "AI in health and medicine," *Nature medicine*, vol. 28, no. 1, pp. 31-38.
- [6]Roberts, P. 2024. *Game AI Uncovered: Volume Two*. CRC Press, 2024.
- [7]Blagden, C. 1975. "XII. Experiments and observations in an heated room," *Philosophical transactions of the Royal Society of London*, no. 65, pp. 111-123.
- [8]Richet, C. 2023. *Thirty years of psychical research*. BoD-Books on Demand.
- [9]Gagge, A. P. & Gonzalez, R. R. 2010. "Mechanisms of heat exchange: biophysics and physiology," *Comprehensive physiology*, pp. 45-84.
- [10]Givoni, B. 2010. "Thermal comfort issues and implications in high-density cities," *Designing high-density cities for social and environmental sustainability*, pp. 87-106.
- [11]Fanger, P. 1988. "Fundamentals of thermal comfort," in *Advances in Solar Energy Technology*: Elsevier, pp. 3056-3061.
- [12]Wu, Y., Jiang, A., Liu, H., Li, B. & Kosonen, R. 2024. "Climate chamber investigation of the effect of indoor thermal histories on thermal adaptation in different seasons," *Energy and Built Environment*, vol. 5, no. 3, pp. 455-463.
- [13]Upadhyay, K., Elangovan, R. & Subudhi, S. 2024. "Quantifying human thermal adaptation for indoor environments through field surveys and climate chamber experiments," *Advances in Building Energy Research*, pp. 1-36.

- der-specific physiological parameters using wearable sensing technology,” *Energy and Buildings*, vol. 166, pp. 391-406.
- [28] Li, D., Menassa, C. C. & Kamat, V. R. 2017. “Personalized human comfort in indoor building environments under diverse conditioning modes,” *Building and Environment*, vol. 126, pp. 304-317.
- [29] Auffenberg, F., Stein, S., & Rogers, A. 2015. “A personalised thermal comfort model using a Bayesian network”.
- [30] Ghahramani, A., Castro, G., Karvigh, S. A., & Becerik-Gerber, B. 2018. “Towards unsupervised learning of thermal comfort using infrared thermography,” *Applied Energy*, vol. 211, pp. 41-49.
- [31] Ličina, V. F. et al., 2018. “Development of the ASHRAE global thermal comfort database II,” *Building and Environment*, vol. 142, pp. 502-512.
- [14] De Dear, R. 2007. “Adaptive comfort applications in Australia and impacts on building energy consumption,” in *Proceedings of the sixth international conference on indoor air quality, ventilation and energy conservation in buildings: sustainable built environment*, Sendai, Japan, pp. 28-31.
- [15] Jain, M., A. Singh, & Chandan, V. 2017. “Portable+ A Ubiquitous and Smart Way Towards Comfortable Energy Savings,” *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, vol. 1, no. 2, pp. 1-22.
- [16] Favero, M., Luparelli, A. & Carlucci, S. 2023. “Analysis of subjective thermal comfort data: A statistical point of view,” *Energy and Buildings*, vol. 281, p. 112755.
- [17] Khodadadi, M., Riazi, L. & Yazdani, S. 2024. “A Novel Ensemble Deep Learning Model for Building Energy Consumption Forecast,” *International Journal of Engineering*, vol. 37, no. 6, pp. 1067-1075, 2024.
- [18] Hou, Z., Lyu, J., Wu, D., Chen, J., Shi, J. & Lian, Z. 2024. “Occupant-Centric Cabin Thermal Sensation Assessment System Based on Low-Cost Thermal Imaging,” *Building and Environment*, p. 111692.
- [19] Zhang, S., Yao, R., Wei, H. & Li, B. 2024. “Prediction of occupant thermal state via infrared thermography and explainable AI,” *Energy and Buildings*, vol. 312, p. 114153.
- [20] Ren, J., Zhang, R., Cao, X. & Kong, X. 2024. “Experimental study on the physiological parameters of occupants under different temperatures and prediction of their thermal comfort using machine learning algorithms,” *Journal of Building Engineering*, vol. 84, p. 108676.
- [21] Khedr, A. M. 2024. “Enhancing supply chain management with deep learning and machine learning techniques: A review,” *Journal of Open Innovation: Technology, Market, and Complexity*, p. 100379.
- [22] Tsague, C. B. N., Seutche, J. C. N., Djeusu, L. N., Chara-Dakou, V. S. & Tchinda, R. 2024. “Application of neural networks to predict indoor air temperature in a building with artificial ventilation: impact of early stopping,” *International Journal of Information Technology*, pp. 1-22.
- [23] Nihar, K., Jain, R. K. & Cheong, S. M. 2024. “Predicting indoor personalized heat stress using wearable sensors and data-driven models,” *Journal of Building Engineering*, vol. 97, p. 110761, 2024.
- [24] Zheng, Y. & Xu, X. 2024. “Predicting indoor 3D airflow distribution using artificial neural networks with two different architectures,” *Energy and Buildings*, vol. 303, p. 113841.
- [25] Farhan, A. A., Pattipati, K., Wang, B. & Luh, P. 2015. “Predicting individual thermal comfort using machine learning algorithms,” in *2015 IEEE International conference on automation science and engineering (CASE)*, IEEE, pp. 708-713.
- [26] Bin, S. & Ke, H. 2010. “Indoor thermal comfort pmv index prediction based on particle swarm algorithm and least square support vector machine,” in *2010 International Conference on Intelligent System Design and Engineering Application*, vol. 1: IEEE, pp. 857-860.
- [27] Chaudhuri, T., Zhai, D., Soh, Y. C., Li, H. & Xie, L. 2018. “Random forest based thermal comfort prediction from gen-