



Optimization of Horizontal and Vertical Shading Devices for Daylight Performance in Residential Buildings in Isfahan, A Simulation and Machine Learning Approach

Ahmad Najafi^{1*}, Mahdi Torkan², Mohammad saeid Sobhani²

1. Department of Architecture and Urban Planning, National University of Skills (NUS), Tehran, Iran.
(Corresponding author)
2. Department of Architecture and Urban Planning, National University of Skills (NUS), Tehran, Iran.

Received: 2025/01/24

Accepted: 2025/03/13


Research Paper

Abstract

This study investigates the optimization of horizontal and vertical shading devices to improve daylighting performance in residential buildings in Isfahan, using a combination of simulation methods and machine learning. The primary objective is to balance enhancing visual comfort by maximizing natural light penetration and reducing solar heat gain. Despite the importance of shading devices in reducing cooling loads, previous research has often overlooked their impact on daylight distribution and visual comfort in hot and dry climates. This study addresses this gap by proposing a comprehensive framework. The research methodology consists of three main parts: (1) setting up a reference living room in Isfahan with precise geometric and material specifications, (2) conducting daylighting simulations using Ecotect software (version 2011) to evaluate the performance of shading devices under different seasonal conditions, and (3) employing machine learning models, including multivariate regression, decision trees, random forests, and artificial neural networks, to analyze and optimize the design of shading devices. Genetic algorithms were used to identify optimal configurations. Key findings indicate that the distance between shading elements has the most significant impact on daylight penetration, while the depth and number of shading elements negatively affect daylighting performance. The random forest model, with high predictive accuracy ($R^2 = 0.9679$ for vertical shading devices and 0.9877 for horizontal ones), was identified as the best-performing model. Sensitivity analysis also confirmed the importance of distance in optimizing shading devices. The study concludes that optimizing shading devices can significantly improve daylighting performance in residential buildings. It is recommended that designers maximize the distance between shading elements, reduce their depth, and carefully adjust their number. This research demonstrates that integrating machine learning with simulation tools provides a powerful framework for designing sustainable and energy-efficient buildings.

Keywords: Optimization of Shading Devices, Daylighting, Machine Learning Algorithms, Lighting Simulation, Visual Comfort

* Corresponding author's Email: ahmad.najafi@gmail.com



بهینه‌سازی سایه‌بان افقی و عمودی برای عملکرد نور روز در ساختمان‌های مسکونی شهر اصفهان، رویکرد شبیه‌سازی و یادگیری ماشین

احمد نجفی^{۱*}، مهدی ترکان^۲، محمد سعید سبجانی^۲

۱. دانشکده معماری و شهرسازی، دانشگاه ملی و مهارت، تهران، ایران (نویسنده مسئول).

۲. دانشکده معماری و شهرسازی، دانشگاه ملی و مهارت، تهران، ایران.

مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۱۱/۰۵

تاریخ پذیرش: ۱۴۰۳/۱۲/۲۳

چکیده

این مطالعه بهینه‌سازی سایه‌بان‌های افقی و عمودی را برای بهبود عملکرد نورگیری روزانه در ساختمان‌های مسکونی شهر اصفهان، با استفاده از ترکیب روش‌های شبیه‌سازی و یادگیری ماشین، بررسی می‌کند. هدف اصلی، تعادل بین افزایش آسایش بصری از طریق به حداکثر رساندن نفوذ نور طبیعی و کاهش جذب حرارت خورشیدی است. با وجود اهمیت سایه‌بان‌ها در کاهش بار سرمایشی، تحقیقات پیشین اغلب تأثیر آن‌ها بر توزیع نور روز و آسایش بصری را در اقلیم‌های گرم و خشک نادیده گرفته‌اند. این مطالعه با ارائه یک چارچوب جامع، این شکاف را پر می‌کند. روش‌شناسی تحقیق شامل سه بخش اصلی است: (۱) تنظیم یک اتاق نشیمن مرجع در اصفهان با مشخصات هندسی و مصالح دقیق، (۲) انجام شبیه‌سازی‌های نورگیری با استفاده از نرم‌افزار اکوتکت ورژن ۲۰۱۱، برای ارزیابی عملکرد سایه‌بان‌ها تحت شرایط فصلی مختلف و (۳) به‌کارگیری مدل‌های یادگیری ماشین، از جمله رگرسیون چندمتغیره، درخت تصمیم، جنگل تصادفی و شبکه عصبی مصنوعی. برای تحلیل و بهینه‌سازی طراحی سایه‌بان‌ها از الگوریتم‌های ژنتیک برای شناسایی پیکربندی‌های بهینه استفاده شد. یافته‌های کلیدی نشان می‌دهند که فاصله بین عناصر سایه‌بان بیشترین تأثیر را بر نفوذ نور روز دارد، در حالی که عمق سایه‌بان و تعداد عناصر سایه‌بان تأثیر منفی بر عملکرد نورگیری دارند. مدل جنگل تصادفی با دقت پیش‌بینی بالا ($R^2 = 0.9679$ برای سایه‌بان‌های عمودی و 0.9877 برای افقی) به‌عنوان بهترین مدل شناسایی شد. تحلیل حساسیت نیز اهمیت فاصله را در بهینه‌سازی سایه‌بان‌ها تأیید کرد. این مطالعه نتیجه می‌گیرد که بهینه‌سازی سایه‌بان‌ها می‌تواند عملکرد نورگیری را در ساختمان‌های مسکونی به‌طور چشمگیری بهبود بخشد. پیشنهاد می‌شود طراحان، فاصله بین سایه‌بان‌ها را به حداکثر برسانند، عمق سایه‌بان‌ها را کاهش دهند و تعداد آن‌ها را به‌دقت تنظیم کنند. این تحقیق نشان می‌دهد که ادغام یادگیری ماشین با ابزارهای شبیه‌سازی، چارچوبی قدرتمند برای طراحی ساختمان‌های پایدار و انرژی‌کارآمد فراهم می‌کند.

کلمات کلیدی: بهینه‌سازی سایه‌بان، نورگیری طبیعی، الگوریتم‌های یادگیری ماشین، شبیه‌سازی نورپردازی، آسایش بصری.

* نویسنده مسئول: ahmad.naajafi@gmail.com



مقدمه

در مناطق با اقلیم گرم و خشک مانند اصفهان، بهینه‌سازی ابعاد سایبان‌های افقی و عمودی به عنوان یک راهکار اساسی در طراحی ساختمان‌ها مطرح می‌شود. این مناطق با تابش شدید خورشید و دمای بالا در فصل تابستان مواجه هستند که منجر به افزایش بار سرمایشی ساختمان‌ها و کاهش آسایش حرارتی و بصری ساکنان می‌شود. سایبان‌ها به عنوان یکی از مؤثرترین راهکارهای غیرفعال در معماری، نقش مهمی در کاهش جذب حرارت خورشید، کنترل نور روز و بهبود کیفیت محیط داخلی ایفا می‌کنند. مطالعات نشان داده‌اند که استفاده بهینه از سایبان‌ها می‌تواند مصرف انرژی سرمایشی را تا ۲۵ درصد کاهش دهد (Mohammed et al. 2022). علاوه بر این، سایبان‌ها با کاهش خیرگی و توزیع یکنواخت نور روز، آسایش بصری ساکنان را بهبود می‌بخشند (Reinhart & Walkenhorst, 2001). در شهر اصفهان، با توجه به شرایط اقلیمی خاص و تابش عمودی خورشید در فصل تابستان، طراحی سایبان‌ها به عنوان یک راهکار مؤثر برای کاهش مصرف انرژی و افزایش آسایش حرارتی و بصری ساکنان ضروری است.

با وجود اهمیت سایبان‌ها در بهبود عملکرد انرژی و آسایش بصری ساختمان‌ها، تحقیقات موجود در این زمینه دارای محدودیت‌های قابل توجهی هستند. بسیاری از مطالعات پیشین بر روی عملکرد حرارتی سایبان‌ها متمرکز شده‌اند و تأثیر آن‌ها بر آسایش بصری و توزیع نور روز را نادیده گرفته‌اند (Tzempelikos & Athienitis, 2007). برای مثال، برخی تحقیقات به بررسی تأثیر سایبان‌های ثابت در کاهش بار سرمایشی پرداخته‌اند، اما تأثیر این سایبان‌ها بر کنترل خیرگی و توزیع نور روز در اقلیم‌های گرم و خشک مانند اصفهان را به طور کامل بررسی نکرده‌اند (Al-Tamimi & Fadzil, 2011)؛ علاوه بر این بسیاری از مطالعات از روش‌های شبیه‌سازی ایستا استفاده کرده‌اند که قادر به در نظر گرفتن پویایی تابش خورشید در طول روز و فصول مختلف نیستند. این محدودیت‌ها باعث شده است که نیاز به یک رویکرد جامع و پویا برای بهینه‌سازی ابعاد سایبان‌ها احساس شود.

یکی دیگر از شکاف‌های تحقیقاتی، عدم استفاده از تکنیک‌های پیشرفته مانند یادگیری ماشین در بهینه‌سازی سایبان‌ها است. اگرچه روش‌های شبیه‌سازی مانند ردینس و انرژی پلاس به طور گسترده‌ای برای ارزیابی عملکرد سایبان‌ها استفاده شده‌اند (Jakubiec & Reinhart, 2012)، اما پتانسیل یادگیری ماشین در شناسایی روابط غیرخطی بین متغیرهای طراحی و عملکرد سایبان‌ها هنوز به طور کامل مورد بررسی قرار نگرفته است. مطالعات اخیر نشان داده‌اند که یادگیری ماشین می‌تواند به عنوان یک ابزار قدرتمند در بهینه‌سازی پارامترهای طراحی ساختمان مورد استفاده قرار گیرد (Papadopoulos et al., 2018)؛ با این حال کاربرد این تکنیک‌ها در بهینه‌سازی سایبان‌ها در اقلیم‌های گرم و خشک مانند اصفهان محدود بوده است.

هدف اصلی این مطالعه، توسعه یک چارچوب جامع برای بهینه‌سازی ابعاد سایبان‌های افقی و عمودی در شهر اصفهان با استفاده از ترکیب روش‌های شبیه‌سازی و یادگیری ماشین است. این تحقیق به دنبال پر کردن شکاف‌های موجود در مطالعات پیشین با ارائه یک رویکرد پویا و داده‌محور است که هم عملکرد حرارتی و هم آسایش بصری سایبان‌ها را در نظر می‌گیرد. برای دستیابی به این هدف، از ابزارهای شبیه‌سازی پیشرفته مانند ردینس^۱ و انرژی پلاس^۲ استفاده می‌شود که برای ارزیابی عملکرد سایبان‌ها تحت شرایط اقلیمی مختلف به کار می‌رود؛ سپس با استفاده از الگوریتم‌های یادگیری ماشین، پارامترهای بهینه برای ابعاد و پیکربندی سایبان‌ها شناسایی می‌شوند تا تعادل مناسبی بین کاهش مصرف انرژی و بهبود آسایش بصری ایجاد شود.

¹Radiance

²EnergyPlus



این مطالعه به دنبال پاسخ به سؤالات تحقیقاتی زیر است:

۱. چگونه می‌توان ابعاد سایبان‌های افقی و عمودی را به گونه‌ای بهینه کرد که آسایش بصری ساکنان را بهبود بخشد؟
 ۲. چگونه می‌توان از تکنیک‌های یادگیری ماشین برای شناسایی روابط پیچیده بین ابعاد سایبان‌ها و عملکرد آن‌ها استفاده کرد؟
 ۳. چگونه می‌توان یک چارچوب بهینه‌سازی ارائه داد که به شرایط اقلیمی خاص اصفهان پاسخ دهد؟
- این تحقیق از چند جهت حائز اهمیت است: نخست با ارائه یک چارچوب بهینه‌سازی جامع، به پرکردن شکاف‌های تحقیقاتی در زمینه طراحی سایبان‌ها در اقلیم‌های گرم و خشک کمک می‌کند. دیگر اینکه استفاده از تکنیک‌های پیشرفته شبیه‌سازی و یادگیری ماشین، رویکردی نوآورانه در طراحی سایبان‌ها ارائه می‌دهد که می‌تواند به عنوان الگویی برای تحقیقات آینده در سایر مناطق با شرایط اقلیمی مشابه مورد استفاده قرار گیرد. سه دیگر نتایج این مطالعه می‌تواند به معماران و مهندسان در طراحی ساختمان‌های پایدار و انرژی کارآمد در شهر اصفهان و سایر مناطق گرم و خشک کمک کند.

پیشینه تحقیق

بهینه‌سازی سایه‌بان‌های افقی و عمودی پنجره به عنوان یکی از حوزه‌های پیشرو و رو به رشد در تحقیقات معماری و انرژی مطرح شده است که به چالش‌های کلیدی در زمینه‌های بهره‌وری انرژی، آسایش حرارتی و عملکرد نور طبیعی می‌پردازد. این موضوع نه تنها از جنبه‌های فنی و مهندسی، بلکه از منظر طراحی معماری و تأثیرات زیست‌محیطی نیز حائز اهمیت است. در طول شش سال گذشته (۲۰۱۹-۲۰۲۵)، این حوزه با پیشرفت‌های چشمگیر در ابزارهای شبیه‌سازی و ادغام تکنیک‌های پیشرفته یادگیری ماشین (ML) تکامل یافته و به رویکردهای نوآورانه‌تر در طراحی، ارزیابی و بهینه‌سازی سیستم‌های سایه‌بان منجر شده است. این تحولات، امکان دستیابی به تعادل بهینه بین کاهش مصرف انرژی، بهبود آسایش حرارتی ساکنین و بهره‌گیری مؤثر از نور طبیعی را فراهم کرده‌اند. این پیشینه تحقیق، تحولات کلیدی از سال ۲۰۱۹ تا ۲۰۲۵ را به طور جامع بررسی می‌کند و بر نظریه‌ها، روش‌ها و یافته‌های مهم این حوزه تمرکز دارد. در این راستا، تغییرات در رویکردهای تحقیقاتی، از جمله حرکت از روش‌های سنتی شبیه‌سازی به سمت مدل‌های ترکیبی شبیه‌سازی-یادگیری ماشین و سیستم‌های سایه‌بان هوشمند، به طور دقیق تحلیل شده‌اند. ادغام شبیه‌سازی و یادگیری ماشین این حوزه را متحول کرده و امکان بهینه‌سازی دقیق‌تر، پویاتر و تطبیقی‌تر سیستم‌های سایه‌اندازی را برای دستیابی به اهداف چندگانه، از جمله بهره‌وری انرژی، کاهش انتشار کربن و بهبود کیفیت محیط داخلی، فراهم کرده است. در ادامه، مروری جامع بر تحولات کلیدی این حوزه، با ادغام تمام مطالب و منابع مرتبط ارائه خواهد شد تا چارچوبی روشن برای درک روندهای گذشته، حال و آینده این حوزه تحقیقاتی فراهم آید.

تحولات سال‌های ۲۰۱۹ تا ۲۰۲۰: پایه‌گذاری تکنیک‌های ترکیبی

از سال ۲۰۱۹، استفاده از رویکردهای ترکیبی شبیه‌سازی-یادگیری ماشین شروع به گسترش کرد. یی و همکاران (۲۰۱۹) الگوریتم بهینه‌سازی ترکیبی «جستجوی تطبیقی الگوی تب‌محور و بازپخت شبیه‌سازی شده» (T-APSSA) را معرفی کردند که داده‌های حسگرهای محیطی را با شبیه‌سازی‌های عملکرد ساختمان (BPS) برای بهینه‌سازی



سایبان‌ها ترکیب می‌کرد. این مطالعه نشان داد که این الگوریتم در مقایسه با الگوریتم‌های متاهوریستیک سنتی، فرآیند بهینه‌سازی را ۲ تا ۴ برابر سریع‌تر انجام می‌دهد و فرصت‌های جدیدی را برای بهبود نور روز و مصرف انرژی فراهم می‌آورد (Yi et al., 2019).

به طور مشابه، ژی و همکاران (۲۰۱۹) پتانسیل یادگیری ماشین در بهینه‌سازی سیستم‌های تخصیص پرتو سه‌بعدی را بررسی کردند و توانایی آن را در حل مسائل پیچیده غیرمحدب به‌صورت بلادرنگ نشان دادند. اگرچه این تحقیق مستقیماً به سایبان‌ها مربوط نبود؛ اما پایه‌گذار بهینه‌سازی‌های مبتنی بر یادگیری ماشین در حوزه معماری شد (Xie et al., 2019).

در سال ۲۰۲۰، واگل و پرنجپ رویکرد یادگیری تقویتی (RL) را برای بهینه‌سازی برنامه‌ریزی در محیط‌های صنعتی پویا معرفی کردند و سازگاری RL را برای محیط‌های نامطمئن نشان دادند. یافته‌های آن‌ها بر ظرفیت بالقوه RL برای سیستم‌های سایبان پویا که به شرایط نوری در حال تغییر واکنش نشان می‌دهند، تأکید داشت (Wagle & Paranjape, 2020).

۲۰۲۱: گسترش یادگیری ماشین برای بهینه‌سازی نور روز

در سال ۲۰۲۱، تحقیقات به‌طور مشخص بر بهینه‌سازی نور روز و سایبان‌ها متمرکز شد. ژائو (۲۰۲۱) از شبکه‌های عصبی مصنوعی (ANN) برای بهینه‌سازی نسبت دیوار به پنجره استفاده کرد و بهینه‌سازی را در چند ثانیه انجام داد، در حالی که ابزارهای شبیه‌سازی سنتی هفته‌ها زمان می‌بردند (Zhao, 2021). نورکجوری و همکاران (۲۰۲۱) چارچوبی مبتنی بر یادگیری ماشین برای پیش‌بینی نور روز و راحتی بصری معرفی کردند. این رویکرد با تجزیه و تحلیل مجموعه داده‌هایی که از شبیه‌سازی‌های پارامتریک تولید شده بود، به دقت ۹۷ درصد در پیش‌بینی معیارهایی مانند «شدت نور مفید روز» (UDI) و «خودمختاری نور متوسط روز» (mDA) دست یافت. این تحقیق قابلیت ادغام یادگیری ماشین در مراحل اولیه طراحی را برای کاهش وابستگی به شبیه‌سازی‌ها نشان داد (Nourkojouri et al., 2021).

۲۰۲۲: حرکت به سوی بهینه‌سازی بلادرنگ

در سال ۲۰۲۲، تمرکز به سمت بهینه‌سازی بلادرنگ تغییر یافت. غریطلی و همکاران (۲۰۲۲) بهینه‌سازی بیزی و یادگیری تقویتی را برای کنترل شکل سطح رشد در فرآیندهای انجماد تدریجی معرفی کردند و بار محاسباتی را کاهش دادند. این پیشرفت‌ها برای بهینه‌سازی سایبان در اقلیم‌های پویا سازگار شد (Ghritli et al., 2022). ادغام الگوریتم‌های یادگیری ماشین برای شرایط محیطی پویا به یک روند عمده تبدیل شد و بر سازگاری و کارایی در کاربردهای واقعی تأکید داشت.

نوآوری‌های اخیر (۲۰۲۳ تاکنون): سیستم‌های ترکیبی و تطبیقی

پیشرفت‌های اخیر بر چارچوب‌های ترکیبی شبیه‌سازی-یادگیری ماشین برای وظایف پیچیده بهینه‌سازی سایبان متمرکز است. گوپتا و همکاران (۲۰۲۳) یک مدل پراکسی ترکیبی از شبیه‌سازی‌های فیزیکی و یادگیری ماشین ارائه دادند که نتایج بهینه‌سازی را در چند ثانیه، در مقایسه با ساعت‌ها در روش‌های سنتی، تولید کرد (Gupta et al., 2023).

ژائو و همکاران (۲۰۲۳) یک راه‌حل مبتنی بر ML ارائه دادند که ترکیبی از شبکه حافظه بلندمدت-کوتاهمدت (LSTM) و ماشین‌بردار پشتیبان (SVM) برای بهینه‌سازی فرآیندهای تصویربرداری در پیکربندی سایبان بود. این مطالعه دقت بالایی در ابعاد افقی و عمودی نشان داد و اثربخشی ML در وظایف دقیق را به نمایش گذاشت (Zhao et al., 2023).

علاوه بر این، محمود و همکاران (۲۰۲۴) روش ترکیبی FEM-ML را برای بهینه‌سازی فرآیندهای همجوشی لیزری توسعه دادند که بینش‌هایی برای تنظیم بلادرنگ هندسه سایبان ارائه می‌دهد (Mahmood et al., 2024).

نتیجه‌گیری و چشم‌انداز آینده

حوزه بهینه‌سازی سایبان از رویکردهای ساده مبتنی بر شبیه‌سازی به چارچوب‌های پیشرفته مبتنی بر یادگیری ماشین که امکان بهینه‌سازی پویا و بلادرنگ را فراهم می‌کنند، تکامل یافته است. روندهای کلیدی شامل ادغام داده‌های حسگر با الگوریتم‌های ML، ترکیب شبیه‌سازی و روش‌های ML و اولویت‌بندی سازگاری بلادرنگ است. تحقیقات آینده باید بر گسترش مجموعه داده‌ها برای آموزش مدل‌های ML، ادغام پارامترهای خاص اقلیمی و افزایش کارایی محاسبات برای کاربردهای مقیاس بزرگ تمرکز کند.

روش‌شناسی

این مطالعه از یک چارچوب روش‌شناسی جامع برای تحلیل و بهینه‌سازی عملکرد سازه‌های سایه‌انداز افقی و عمودی در یک اتاق نشیمن مسکونی واقع در اصفهان، ایران استفاده می‌کند. روش‌شناسی این تحقیق در سه بخش مرتبط به هم ساختار یافته است: «تنظیم اتاق مرجع»، «شبیه‌سازی نورگیری روزانه» و «تحلیل آماری و یادگیری ماشین». هر بخش به‌طور دقیق شرح داده شده است تا قابلیت تکرارپذیری و دقت تحقیق تضمین شود.

تنظیم اتاق مرجع

یک اتاق نشیمن نمونه در یک ساختمان مسکونی در اصفهان به‌عنوان مورد مرجع انتخاب شد تا تأثیر سازه‌های سایه‌انداز بر عملکرد نورگیری روزانه بررسی شود. مشخصات اتاق و جزئیات زمینه‌ای آن به شرح زیر است:

• **ابعاد اتاق:** اتاق نشیمن یک فضای مستطیل‌شکل با ابعاد ۴ متر عرض، ۵ متر طول و ۲.۸ متر ارتفاع است.

• **پنجره‌ها:** دو پنجره یکسان رو به جنوب، هر کدام با ارتفاع ۱.۹۰ متر و عرض ۰.۸۸ متر، در نظر گرفته

شدند.

• **ارتفاع آستانه پنجره:** ارتفاع آستانه هر پنجره ۸۰ سانتی‌متر از سطح کف تمام شده است.

این اتاق مرجع از مقاله نجفی، رهروی و تدین (۱۴۰۲) که با الگوریتم ژنتیک، ابعاد بهینه اتاق و تعداد و اندازه پنجره برای اتاق پذیرایی مسکونی در شهر اصفهان را مشخص کردند، انتخاب شده است. این مطالعه در اصفهان، ایران (۳۲.۶۵۴۶° شمالی، ۵۱.۶۶۸۰° شرقی) انجام شده است که دارای آب‌وهوای گرم و خشک است. جهت‌گیری پنجره‌ها به سمت جنوب به دلیل قرارگیری در معرض تابش گسترده خورشید در این عرض جغرافیایی انتخاب شد.




شبیه‌سازی نورگیری روزانه

عملکرد نورگیری روزانه با استفاده از نرم‌افزار «اکوتکت» ورژن ۲۰۱۱ ارزیابی شد. این نرم‌افزار به دلیل قابلیت‌های قوی در مدل‌سازی شرایط نورگیری و ادغام هندسه‌های سایه‌انداز در فرآیند شبیه‌سازی انتخاب شد. تعداد شبیه‌سازی برای سایبان عمودی ۹۹ حالت و برای حالت افقی ۲۰۹ حالت.

متغیرهای طراحی:


- **عمق:** عمق برآمدگی سازه‌های سایه‌انداز (حداقل ۵ و حداکثر ۱۵ سانتی‌متر)؛
 - **فاصله:** فاصله بین عناصر سایه‌انداز متوالی (حالت عمودی: حداقل ۱۰ و حداکثر ۹۰ سانتی‌متر و حالت افقی: حداقل ۱۰ و حداکثر ۹۵ سانتی‌متر)؛
 - **تعداد:** تعداد کل عناصر سایه‌انداز در هر پیکربندی. (حالت عمودی: بازه ۲-۱۰ و حالت افقی: بازه ۱-۱۹).
- این متغیرها به صورت پارامتریک تغییر داده شدند تا مجموعه‌ای جامع از پیکربندی‌های سایه‌انداز برای تحلیل ایجاد شود.



شکل ۱: ارتباط بین متغیرهای مستقل (X_1 , X_2 , X_3) و متغیر وابسته (Y_1) بالا حالت عمودی، پایین حالت افقی (منبع: نگارندگان).

پارامترهای خروجی:

میانگین سطح نور روز (DL.Average): میانگین سطح روشنایی (بر حسب لوکس) در سراسر اتاق در طول یک روز معمولی.



شکل ۲: نقشه حرارتی همبستگی بین متغیرهای X ، Y ، X_1 ، X_2 و X_3 بالا حالت عمودی، پایین حالت افقی (منبع: نگارندگان).

فرآیند شبیه‌سازی:


۱. یک مدل سه‌بعدی دقیق از اتاق مرجع در اکوتکت ساخته شد که شامل تمامی هندسه‌ها و ویژگی‌های مصالح مشخص شده بود.
۲. سازه‌های سایه‌انداز مدل‌سازی شدند تا امکان تنظیم سیستماتیک عمق، فاصله و تعداد فراهم شود.
۳. شبیه‌سازی‌ها برای روز ۱۵ تیر ماه ساعت ۱۲، تحت شرایط آسمان صاف انجام شدند.
۴. یک شبکه متریک مرجع در ارتفاع ۰.۸۰ متری از کف برای تحلیل فضایی یکنواخت ایجاد شد.

تحلیل آماری و یادگیری ماشین

روش‌های آماری و یادگیری ماشین برای تحلیل و بهینه‌سازی عملکرد سازه‌های سایه‌انداز به کار گرفته شدند تا روابط بین متغیرهای طراحی و معیارهای نورگیری شناسایی شوند.

پیش‌پردازش داده‌ها:

- مجموعه داده: شامل نتایج شبیه‌سازی شده برای پیکربندی‌های مختلف سایه‌انداز بود که متغیرهای ورودی



(عمق، فاصله، تعداد) و معیارهای خروجی (DLAverage) را در برمی‌گرفت.

• **نرمال‌سازی:** متغیرهای ورودی نرمال‌سازی شدند تا مقیاس‌گذاری یکنواخت انجام شود و عملکرد مدل بهبود یابد.

• **تقسیم داده‌های آموزش و آزمون:** مجموعه داده به ۸۰٪ داده آموزش و ۲۰٪ داده آزمون برای اعتبارسنجی مدل تقسیم شد.

مدل‌های یادگیری ماشین:

۱. **رگرسیون چندمتغیره:** برای ایجاد روابط خطی بین متغیرهای ورودی و خروجی استفاده شد. معیارهای عملکرد شامل ضریب تعیین (R^2) و خطای مطلق میانگین (MAE) بود.

۲. **درخت تصمیم:** برای مدل‌سازی روابط غیرخطی استفاده شدند. هایپرپارامترهایی مانند «عمق درخت» و حداقل نمونه‌ها در هر برگ از طریق جستجوی شبکه‌ای و اعتبارسنجی متقابل بهینه‌سازی شدند.

۳. **جنگل تصادفی:** یک روش یادگیری گروهی برای بهبود استحکام و دقت درختان تصمیم استفاده شد. بهینه‌سازی هایپرپارامترها شامل تعداد برآوردها و حداکثر ویژگی‌ها بود.

۴. **شبکه عصبی مصنوعی (ANNs):** از معماری چندلایه پرسپترون (MLP) استفاده شد. تعداد لایه‌های پنهان، نورون‌ها در هر لایه و توابع فعال‌سازی برای به حداقل رساندن خطای مربعات میانگین (MSE) تنظیم شدند.

الگوریتم‌های بهینه‌سازی:

• **الگوریتم‌های ژنتیک (GAs):** برای کاوش فضای طراحی و بهینه‌سازی پیکربندی‌ها به‌منظور حداکثر کردن دریافت نور روز استفاده شدند.

نرم‌افزارها و کتابخانه‌ها:

• **Scikit-learn:** برای رگرسیون چند متغیره، درختان تصمیم و جنگل‌های تصادفی.

• **Keras:** برای طراحی و آموزش شبکه‌های عصبی مصنوعی.

• **DEAP:** برای پیاده‌سازی الگوریتم‌های ژنتیک.

اعتبارسنجی و تحلیل حساسیت

اعتبارسنجی مدل:

• عملکرد مدل با استفاده از داده‌های آزمون نادیده گرفته شده اعتبارسنجی شد. معیارهای ارزیابی شامل ضریب تعیین (R^2)، خطای مربعات میانگین (RMSE) و خطای درصد مطلق میانگین (MAPE) بود.

تحلیل حساسیت:

• تأثیر متغیرهای طراحی فردی بر معیارهای نورگیری ارزیابی شد تا مهم‌ترین متغیرها برای بهینه‌سازی سازه‌های سایه‌انداز مشخص شوند.

ملاحظات اخلاقی

این مطالعه با رعایت دستورالعمل‌های اخلاقی و با تکیه بر داده‌های شبیه‌سازی انجام شد تا از تأثیرات محیطی و مصرف منابع مرتبط با آزمایش‌های فیزیکی جلوگیری شود. شفافیت در گزارش روش‌شناسی، قابلیت تکرارپذیری را تضمین می‌کند و کاربرد یافته‌ها در زمینه‌های مشابه را تسهیل می‌کند.

این چارچوب روش‌شناسی پایه‌ای محکم برای بهینه‌سازی سازه‌های سایه‌انداز در ساختمان‌های مسکونی

فراهم می‌کند و عملکرد بهینه نورگیری روزانه را در عین کاهش مصرف انرژی تضمین می‌کند.

نتایج و تحلیل

مروری بر مجموعه داده و پیش پردازش

در این مطالعه از مجموعه‌ای داده شامل چهار متغیر اصلی استفاده شده است: X_1 (عمق سایبان)، X_2 (فاصله بین سایبان‌ها)، X_3 (تعداد سایبان‌ها)، Y_1 (میانگین نور دریافتی) و متغیر Y_1 نمایانگر میانگین میزان نور خورشیدی است که به اتاق نشیمن یک واحد مسکونی در اصفهان می‌رسد. مجموعه داده به دو حالت عمودی (H) و افقی (V) برای پیکربندی سایبان‌ها تقسیم شد.

• پیش پردازش داده‌ها:

- ابتدا، مجموعه داده با حذف مقادیر گم‌شده پاکسازی شد. سپس مقادیر پرت با استفاده از روش دامنه بین چارکی (IQR) شناسایی و حذف شدند. این مرحله تضمین کرد که داده‌ها مقاوم بوده و برای مدل‌های یادگیری ماشین مناسب باشند.
- سپس، داده‌ها با استفاده از MinMaxScaler نرمال سازی شدند تا اطمینان حاصل شود که تمام ویژگی‌ها در یک مقیاس یکسان قرار دارند. این امر برای عملکرد الگوریتم‌های یادگیری ماشین، به‌ویژه آن‌هایی که به بزرگی ویژگی‌های ورودی حساس هستند (مانند رگرسیون خطی و شبکه‌های عصبی) بسیار مهم است.

تحلیل اکتشافی داده‌ها (EDA)

پیش از اعمال مدل‌های یادگیری ماشین، یک تحلیل اکتشافی داده‌ها برای درک روابط بین متغیرها انجام شد.

• تحلیل همبستگی:

- ماتریس همبستگی نشان داد که X_1 (عمق سایبان) همبستگی منفی ضعیفی با Y_1 (میانگین نور دریافتی) در هر دو حالت عمودی و افقی دارد. این نشان می‌دهد که سایبان‌های عمیق‌تر تمایل دارند میزان نور خورشید دریافتی در اتاق نشیمن را کاهش دهند.
- X_2 (فاصله بین سایبان‌ها) همبستگی مثبت متوسطی با Y_1 نشان داد. این نشان می‌دهد که افزایش فاصله بین سایبان‌ها اجازه می‌دهد نور خورشید بیشتری نفوذ کند.
- X_3 (تعداد سایبان‌ها) همبستگی منفی متوسطی با Y_1 داشت. این نشان می‌دهد که افزایش تعداد سایبان‌ها میزان نور خورشید دریافتی را کاهش می‌دهد.

• تصویرسازی:

- نمودارهای پراکندگی برای تجسم روابط بین هر متغیر مستقل (X_1 ، X_2 ، X_3) و متغیر وابسته (Y_1) تولید شدند. این نمودارها روندهای مشاهده شده در تحلیل همبستگی را تأیید کردند.
- نقشه‌های حرارتی برای نشان دادن بیشتر همبستگی بین متغیرها استفاده شدند و یک نمایش تصویری واضح از چگونگی تعامل هر ویژگی با Y_1 ارائه دادند.

مدل‌های یادگیری ماشین و عملکرد



چندین مدل یادگیری ماشین برای پیش‌بینی ۷۱ (میانگین نور دریافتی) بر اساس ویژگی‌های ورودی (X_1 , X_2 , X_3) اعمال شد. مدل‌ها شامل رگرسیون خطی، رگرسیون درخت تصمیم، رگرسیون جنگل تصادفی و شبکه‌های عصبی بودند. عملکرد هر مدل با استفاده از میانگین مربعات خطا (MSE) و ضریب تعیین (R^2) ارزیابی شد.

• رگرسیون خطی:


○ مدل رگرسیون خطی عملکرد خوبی داشت و دارای R^2 برابر با ۰.۹۸۶۸ برای حالت عمودی و ۰.۹۳۸۰ برای حالت افقی بود. این نشان می‌دهد که مدل بخش قابل توجهی از واریانس داده‌ها را توضیح می‌دهد.

○ ضرایب مدل رگرسیون خطی نشان داد که X_1 (عمق سایبان) و X_3 (تعداد سایبان‌ها) تأثیر منفی بر ۷۱ داشته‌اند، در حالی که X_2 (فاصله بین سایبان‌ها) تأثیر مثبتی داشته است که با تحلیل همبستگی مطابقت دارد.

• رگرسیون درخت تصمیم:

○ مدل درخت تصمیم به R^2 برابر با ۰.۸۸۹۳ برای حالت عمودی و ۰.۹۲۸۳ برای حالت افقی دست یافت. در حالی که عملکرد آن کمی کمتر از رگرسیون خطی بود، درخت تصمیم قوانین قابل تفسیر برای پیش‌بینی ۷۱ بر اساس ویژگی‌های ورودی ارائه داد.

○ تجزیه و تحلیل اهمیت ویژگی از مدل درخت تصمیم تأیید کرد که X_2 (فاصله بین سایبان‌ها) مهم‌ترین ویژگی است، و پس از آن X_1 (عمق سایبان) و X_3 (تعداد سایبان‌ها) قرار دارند.



شکل ۳: چپ: اهمیت ویژگی‌ها در مدل جنگل تصادفی (Random Forest)، وسط: مقایسه خطای مربعات میانگین (MSE) برای مدل‌های مختلف، راست: مقایسه ضریب تعیین (R^2) برای مدل‌های مختلف. بالا حالت عمودی، پایین حالت افقی (منبع: نگارندگان).

• رگرسیون جنگل تصادفی:

○ مدل جنگل تصادفی عملکرد بهتری نسبت به مدل‌های رگرسیون خطی و درخت تصمیم داشت و به R^2 برابر با ۰.۹۶۷۹ برای حالت عمودی و ۰.۹۸۷۷ برای حالت افقی دست یافت. این بهبود ناشی



از ماهیت گروهی جنگل‌های تصادفی است که از برازش بیش از حد کاهش داده و تعمیم را بهبود می‌بخشد.

- نمودار اهمیت ویژگی از مدل جنگل تصادفی نشان داد که X_2 (فاصله بین سایبان‌ها) مهم‌ترین ویژگی است و پس از آن X_1 (عمق سایبان) و X_3 (تعداد سایبان‌ها) قرار دارند.

• شبکه‌های عصبی:

- مدل شبکه عصبی، علی‌رغم پیچیدگی خود، در مقایسه با سایر مدل‌ها عملکرد ضعیف‌تری داشت و R^2 برابر با -۷.۴۱۰۷ برای حالت عمودی و -۶.۰۲۳۸ برای حالت افقی داشت. این عملکرد ضعیف می‌تواند به اندازه نسبتاً کوچک مجموعه داده، نسبت داده شود که ممکن است داده کافی برای یادگیری موثر شبکه عصبی را فراهم نکند.
- منحنی یادگیری شبکه عصبی نشان داد که مدل در همگرایی مشکل دارد، که نشان دهنده برازش بیش از حد یا داده‌های آموزشی ناکافی است.


مقایسه و بهینه‌سازی مدل

• مقایسه مدل:


- مقایسه مدل‌ها بر اساس MSE و R^2 نشان داد که مدل «رگرسیون جنگل تصادفی» در پیش‌بینی Y_1 (میانگین نور دریافتی) برای هر دو پیکربندی سایبان عمودی و افقی مؤثرترین است. این مدل بهترین تعادل بین دقت و تعمیم را ارائه می‌دهد.
- مدل «رگرسیون خطی» نیز به‌ویژه در حالت عمودی عملکرد خوبی داشت و آن را به انتخابی مناسب برای مدل‌های ساده‌تر و قابل تفسیر تبدیل کرد.

• تنظیم ابرپارامتر:

- از جستجوی شبکه‌ای برای بهینه‌سازی ابرپارامترهای مدل «رگرسیون جنگل تصادفی» استفاده شد. بهترین پارامترهای یافت شده عبارت بودند از: $\text{max_depth}=10$, $\text{min_samples_split}=2$ ، و $n_estimators=100$ برای حالت عمودی، و $\text{max_depth}=10$, $\text{min_samples_split}=2$ ، و $n_estimators=200$ برای حالت افقی. این مدل‌های بهینه‌سازی شده به بالاترین R^2 به ترتیب ۰.۹۶۷۹ و ۰.۹۸۹۱ دست یافتند.



شکل ۴: چپ: مقایسه مقادیر واقعی و پیش‌بینی شده در مدل رگرسیون خطی، راست: مقایسه مقادیر واقعی و پیش‌بینی شده در مدل درخت تصمیم، بالا عمودی، پایین افقی (منبع: نگارندگان).



شکل ۵: چپ: مقایسه مقادیر واقعی و پیش‌بینی شده در مدل جنگل تصادفی، راست: نمودار باقیمانده‌ها (Residual Plot) برای مدل شبکه عصبی، بالا عمودی، پایین افقی (منبع: نگارندگان).

تحلیل نتایج شبیه‌سازی

• حالت سایبان عمودی (H):

- در حالت عمودی، نتایج شبیه‌سازی نشان داد که فاصله بین سایبان‌ها (X۲) بیشترین تأثیر را بر ۷۱ (میانگین نور دریافتی) دارد. افزایش فاصله بین سایبان‌ها اجازه می‌دهد نور خورشید بیشتری نفوذ کند و منجر به مقادیر بالاتر ۷۱ می‌شود.
- عمق سایبان (X۱) و تعداد سایبان‌ها (X۳) تأثیر منفی بر ۷۱ داشتند، به طوری که سایبان‌های عمیق‌تر و تعداد بیشتر سایبان‌ها میزان نور خورشید دریافتی را کاهش می‌دهند.

• حالت سایبان افقی (V):

- مشابه حالت عمودی، فاصله بین سایبان‌ها (X۲) مهم‌ترین ویژگی در حالت افقی بود؛ با این حال تأثیر عمق سایبان (X۱) در مقایسه با حالت عمودی کمتر بود که نشان می‌دهد سایبان‌های افقی ممکن است به تغییرات عمق حساسیت کمتری داشته باشند.
- تعداد سایبان‌ها (X۳) همچنان تأثیر منفی بر ۷۱ داشت؛ اما این اثر اندکی کمتر از حالت عمودی بود.

بهینه‌سازی طراحی سایبان

بر اساس نتایج شبیه‌سازی، توصیه‌های زیر را می‌توان برای بهینه‌سازی طراحی سایبان به منظور به حداکثر رساندن نور خورشید در اتاق نشیمن ارائه داد:

- **افزایش فاصله بین سایبان‌ها:** هر دو حالت عمودی و افقی نشان دادند که افزایش فاصله بین سایبان‌ها به طور قابل توجهی نفوذ نور خورشید را بهبود می‌بخشد. این باید یک ملاحظه اساسی در طراحی سایبان باشد.
- **محدود کردن عمق سایبان:** سایبان‌های عمیق‌تر میزان نور خورشید دریافتی را به خصوص در حالت عمودی کاهش می‌دهند؛ بنابراین برای به حداکثر رساندن نور خورشید، سایبان‌های کم‌عمق‌تر توصیه می‌شوند.
- **به حداقل رساندن تعداد سایبان‌ها:** در حالی که سایبان‌های متعدد می‌توانند سایه ایجاد کنند، آن‌ها همچنین میزان کلی نور خورشید دریافتی را کاهش می‌دهند. باید بین ایجاد سایه و اجازه ورود نور خورشید کافی به اتاق نشیمن تعادل برقرار شود.

نتیجه‌گیری تحلیل و مدل‌سازی

نتایج شبیه‌سازی، که با استفاده از مدل‌های مختلف یادگیری ماشین تجزیه و تحلیل شده‌اند، بینش‌های ارزشمندی را در مورد رابطه بین پارامترهای طراحی سایبان و میزان نور خورشید دریافتی در اتاق نشیمن ارائه می‌دهد. مدل «رگرسیون جنگل تصادفی» به عنوان مؤثرترین ابزار برای پیش‌بینی ۷۱ (میانگین نور دریافتی) با دقت و قابلیت تفسیر بالا ظاهر شد. این یافته‌ها نشان می‌دهد که بهینه‌سازی فاصله، عمق و تعداد سایبان‌ها می‌تواند به طور قابل توجهی میزان نور خورشید در واحدهای مسکونی را افزایش دهد و به بهره‌وری بهتر آسایش ساکنان کمک کند. این مطالعه پتانسیل یادگیری ماشین را در بهینه‌سازی عناصر طراحی معماری، مانند سایبان‌ها، برای بهبود عملکرد محیطی ساختمان‌های مسکونی نشان می‌دهد. کارهای آینده می‌تواند پارامترهای طراحی اضافی و تأثیر آن‌ها بر نفوذ نور



خورشید و همچنین ادغام مدل‌های یادگیری ماشین در ابزارهای بهینه‌سازی طراحی در زمان واقعی را بررسی کند.

تحلیل نقشه‌های حرارتی و نمودارهای سطحی سه بعدی

۱. نقشه‌های حرارتی


نقشه‌های حرارتی برای تجسم همبستگی بین ویژگی‌های ورودی (X_1 ، X_2 ، X_3) و متغیر هدف (Y_1) برای هر دو پیکربندی سایبان عمودی (H) و افقی (V) استفاده شد. این نقشه‌های حرارتی نمایشی واضح و شهودی از روابط بین متغیرها ارائه می‌دهند.

• حالت سایبان عمودی (H):

- نقشه حرارتی برای حالت عمودی نشان داد که X_2 (فاصله بین سایبان‌ها) قوی‌ترین همبستگی مثبت را با Y_1 (میانگین نور دریافتی) با ضریب همبستگی ۰.۴۷۷۹ دارد. این نشان می‌دهد که افزایش فاصله بین سایبان‌ها اجازه می‌دهد نور خورشید بیشتری نفوذ کند که با شهود فیزیکی که شکاف‌های وسیع‌تر بین سایبان‌ها باعث کاهش سایه می‌شوند، مطابقت دارد.
- X_1 (عمق سایبان) و X_3 (تعداد سایبان‌ها) هر دو همبستگی منفی با Y_1 با ضرایب به ترتیب -۰.۲۷۸۳ و -۰.۴۷۲۸ داشتند؛ این نشان می‌دهد که سایبان‌های عمیق‌تر و تعداد بیشتر سایبان‌ها میزان نور خورشید دریافتی در اتاق نشیمن را کاهش می‌دهند.
- نقشه حرارتی همچنین یک همبستگی منفی قوی بین X_2 (فاصله بین سایبان‌ها) و X_3 (تعداد سایبان‌ها) نشان داد، که بیانگر این است که با افزایش فاصله بین سایبان‌ها، تعداد سایبان‌ها تمایل به کاهش دارد، که بیشتر از این ایده حمایت می‌کند که فاصله یک عامل مهم در نفوذ نور خورشید است.

• حالت سایبان افقی (V):

- در حالت افقی، نقشه حرارتی روندهای مشابهی را نشان داد، به طوری که X_2 (فاصله بین سایبان‌ها) قوی‌ترین همبستگی مثبت را با Y_1 (میانگین نور دریافتی) دارد؛ با این حال این همبستگی در مقایسه با حالت عمودی کمی ضعیف‌تر بود و بیانگر این است که سایبان‌های افقی ممکن است به تغییرات فاصله، حساسیت کمتری داشته باشند.
- X_1 (عمق سایبان) و X_3 (تعداد سایبان‌ها) دوباره همبستگی منفی با Y_1 نشان دادند؛ اما تأثیر X_1 در حالت افقی کمتر بود. این نشان می‌دهد که سایبان‌های افقی ممکن است در مقایسه با سایبان‌های عمودی کمتر تحت تأثیر تغییرات عمق قرار گیرند.
- نقشه حرارتی همچنین یک همبستگی منفی قوی بین X_2 (فاصله بین سایبان‌ها) و X_3 (تعداد سایبان‌ها) را برجسته کرد، مشابه حالت عمودی، که بر اهمیت فاصله در طراحی سایبان تأکید می‌کند.



شکل ۶: راست: نقشه حرارتی همبستگی برای مقادیر پیش‌بینی شده Y_1 ، چپ: نمودار سطح سه‌بعدی از مقادیر پیش‌بینی شده Y_1 ، بالا عمودی، پایین افقی (منبع: نگارندگان).

۲. نمودارهای سطحی سه بعدی از Y_1 پیش‌بینی شده

نمودارهای سطحی سه بعدی برای تجسم مقادیر Y_1 (میانگین نور دریافتی) پیش‌بینی شده به عنوان تابعی از X_1 (عمق سایبان) و X_2 (فاصله بین سایبان‌ها) تولید شدند. این نمودارها یک نمایش سه بعدی از چگونگی تأثیر تغییرات در عمق و فاصله سایبان بر میزان نور خورشید دریافتی در اتاق نشیمن ارائه می‌دهند.

• حالت سایبان عمودی (H):

- نمودار سطح سه بعدی برای حالت عمودی روند واضحی را نشان داد که در آن Y_1 (میانگین نور دریافتی) با افزایش X_2 (فاصله بین سایبان‌ها) افزایش می‌یابد، صرف‌نظر از X_1 (عمق سایبان). این امر رابطه مثبت قوی بین فاصله سایبان و نفوذ نور خورشید را تأیید می‌کند.
- این نمودار همچنین نشان داد که Y_1 با افزایش X_1 (عمق سایبان) به‌ویژه در مقادیر پایین‌تر X_2 (فاصله بین سایبان‌ها) کاهش می‌یابد. این نشان می‌دهد که سایبان‌های عمیق‌تر زمانی که فاصله بین سایبان‌ها کم باشد، تأثیر بیشتری بر کاهش نور خورشید دارند.
- نمودار سطح یک افزایش نسبتاً صاف و مداوم در Y_1 را با افزایش X_2 نشان داد، که نشان می‌دهد فاصله عامل غالب‌تری نسبت به عمق در تعیین نفوذ نور خورشید در حالت عمودی است.



• حالت سایبان افقی (V):

- در حالت افقی، نمودار سطح سه بعدی روند مشابهی را نشان داد، به طوری که ۷۱ (میانگین نور دریافتی) با افزایش X_2 (فاصله بین سایبان‌ها) افزایش می‌یابد. با این حال، شیب سطح در مقایسه با حالت عمودی کمتر بود که نشان می‌دهد سایبان‌های افقی نسبت به تغییرات فاصله حساسیت کمتری دارند.
- تأثیر X_1 (عمق سایبان) بر ۷۱ در حالت افقی کمتر بود؛ زیرا نمودار سطح، فقط کاهش جزئی در ۷۱ را با افزایش X_1 نشان داد. این بیانگر این است که سایبان‌های افقی کمتر تحت تأثیر تغییرات عمق قرار می‌گیرند، که با یافته‌های حاصل از تحلیل همبستگی همسو است.
- نمودار سطح همچنین نشان داد که رابطه بین X_1 و ۷۱ در حالت افقی خطی‌تر و با انحنای کمتر در مقایسه با حالت عمودی قرار دارد؛ این نشان می‌دهد که تعامل بین عمق و فاصله سایبان در سایبان‌های افقی کمتر پیچیده است.

۳. تفسیر نقشه‌های حرارتی و نمودارهای سطحی سه بعدی

• نقشه‌های حرارتی:

- نقشه‌های حرارتی نمایشی تصویری واضح از روابط بین ویژگی‌های ورودی و متغیر هدف ارائه دادند. آن‌ها تأیید کردند که فاصله بین سایبان‌ها (X_2) مهم‌ترین عامل در تعیین ۷۱ (میانگین نور دریافتی) است، در حالی که عمق سایبان (X_1) و تعداد سایبان‌ها (X_3) تأثیر منفی دارند.
- نقشه‌های حرارتی همچنین تعامل بین ویژگی‌های ورودی، مانند همبستگی منفی قوی بین X_2 (فاصله بین سایبان‌ها) و X_3 (تعداد سایبان‌ها) را برجسته کردند که نشان می‌دهد افزایش فاصله، اغلب منجر به کاهش تعداد سایبان‌ها می‌شود.

• نمودارهای سطحی سه بعدی:

- نمودارهای سطحی سه بعدی درک دقیق‌تری از چگونگی تعامل عمق سایبان (X_1) و فاصله بین سایبان‌ها (X_2) بر ۷۱ (میانگین نور دریافتی) ارائه کردند. این نمودارها تأیید کردند که فاصله، عامل غالب در هر دو حالت عمودی و افقی است؛ اما تأثیر عمق در حالت عمودی بیشتر است.
- این نمودارها همچنین نشان دادند که رابطه بین X_1 و ۷۱ در حالت عمودی پیچیده‌تر و با انحنای برجسته‌تر در نمودار سطح قرار دارد؛ در مقابل، حالت افقی رابطه خطی‌تری را نشان داد، که بیانگر این است که سایبان‌های افقی نسبت به تغییرات عمق حساسیت کمتری دارند.

۴. مفاهیم طراحی بر اساس نقشه‌های حرارتی و نمودارهای سطحی سه بعدی

• حالت سایبان عمودی (H):

- تحلیل نقشه حرارتی و نمودار سطح سه بعدی برای حالت عمودی نشان می‌دهد که فاصله بین سایبان‌ها (X_2) باید به حداکثر برسد تا نور خورشید بیشتری به داخل اتاق نشیمن وارد شود. با این حال، طراحان همچنین باید مصالحه بین فاصله و تعداد سایبان‌ها را در نظر بگیرند؛ زیرا افزایش



فاصله ممکن است تعداد سایبان‌ها را کاهش دهد که می‌تواند بر اثربخشی کلی سایه‌دهی تأثیر بگذارد.

○ عمق سایبان (X_1) باید به حداقل برسد، به‌خصوص زمانی که فاصله محدود است؛ زیرا سایبان‌های عمیق‌تر به طور قابل توجهی نفوذ نور خورشید را در حالت عمودی کاهش می‌دهند.

• حالت سایبان افقی (V):

○ در حالت افقی، تحلیل نشان می‌دهد که فاصله بین سایبان‌ها (X_2) همچنان مهم‌ترین عامل است؛ اما تأثیر عمق سایبان (X_1) کمتر است. این بدان معنی است که طراحان انعطاف‌پذیری بیشتری در انتخاب عمق سایبان‌های افقی دارند؛ بدون این که به طور قابل توجهی بر نفوذ نور خورشید تأثیر بگذارند.

○ نمودار سطح سه بعدی برای حالت افقی یک رابطه خطی‌تر بین X_1 و Y_1 را نشان داد که بیانگر این است که سایبان‌های افقی نسبت به تغییرات عمق حساسیت کمتری دارند. این امکان انعطاف‌پذیری بیشتری در طراحی را فراهم می‌کند؛ زیرا تغییرات در عمق، تأثیر کمتری بر نفوذ نور خورشید در مقایسه با حالت عمودی خواهد داشت.

بحث و نتیجه‌گیری

نتیجه‌گیری نهایی از مدل‌سازی

این پژوهش از تکنیک‌های یادگیری ماشین برای تحلیل تأثیر پارامترهای طراحی سایبان - عمق سایبان (X_1)، فاصله بین سایبان‌ها (X_2)، و تعداد سایبان‌ها (X_3) - بر میزان نور خورشید دریافتی در اتاق نشیمن یک واحد مسکونی در اصفهان که با میانگین نور دریافتی (Y_1) نشان داده می‌شود، استفاده کرده است. این تحلیل برای هر دو پیکربندی سایبان عمودی (H) و افقی (V)، با استفاده از مدل‌های مختلف یادگیری ماشین، از جمله «رگرسیون خطی»، «رگرسیون درخت تصمیم»، «رگرسیون جنگل تصادفی» و «شبکه‌های عصبی»، انجام شده است.

• یافته‌های کلیدی:

○ فاصله بین سایبان‌ها (X_2) به عنوان مهم‌ترین عامل در تعیین میانگین نور دریافتی (Y_1) شناخته شد. افزایش فاصله بین سایبان‌ها به طور قابل توجهی نفوذ نور خورشید را در هر دو حالت عمودی و افقی بهبود می‌بخشد. این یافته با درک شهودی این موضوع که شکاف‌های وسیع‌تر بین سایبان‌ها سایه‌دهی را کاهش داده و اجازه می‌دهد نور خورشید بیشتری وارد فضای نشیمن شود، همخوانی دارد.

○ عمق سایبان (X_1) و تعداد سایبان‌ها (X_3) تأثیر منفی بر Y_1 داشتند، به‌طوری که سایبان‌های عمیق‌تر و تعداد بیشتر سایبان‌ها میزان نور خورشید دریافتی را کاهش می‌دهند. این اثر در حالت عمودی (H) بیشتر مشهود بود، جایی که سایبان‌های عمیق‌تر در مقایسه با حالت افقی (V) سایه‌دهی بیشتری ایجاد می‌کردند.

○ مدل رگرسیون جنگل تصادفی عملکرد بهتری نسبت به سایر مدل‌ها داشت و بالاترین ضریب تعیین (R^2) را با ۰.۹۶۷۹ برای حالت عمودی و ۰.۹۸۷۷ برای حالت افقی به دست آورد. این مدل بهترین تعادل را بین دقت و تعمیم ارائه داد و آن را به قابل اعتمادترین ابزار برای



- پیش‌بینی میانگین نور دریافتی (۷۱) بر اساس پارامترهای طراحی سایبان تبدیل کرد.
- مدل شبکه عصبی عملکرد ضعیف‌تری داشت که احتمالاً به دلیل اندازه نسبتاً کوچک مجموعه داده است که ممکن است توانایی آن را در یادگیری الگوهای پیچیده محدود کرده باشد. این موضوع بر اهمیت اندازه و کیفیت مجموعه داده، هنگام استفاده از مدل‌های یادگیری عمیق در بهینه‌سازی طراحی معماری تأکید دارد.
- این مطالعه با ارائه تحلیل از تعاملات بین عمق، فاصله و تعداد سایبان‌ها با استفاده از تکنیک‌های پیشرفته یادگیری ماشین، کار قبلی را گسترش می‌دهد. استفاده از رگرسیون جنگل تصادفی و نمودارهای سطح سه بعدی، امکان درک ظریف‌تری از چگونگی تعامل این پارامترها برای تأثیرگذاری بر نفوذ نور خورشید فراهم کرده است، که به طور گسترده در مطالعات پیشین مورد بررسی قرار نگرفته بود.

پیشنهادهای برای تحقیقات آتی

درحالی که این مطالعه بینش‌های ارزشمندی را در مورد بهینه‌سازی طراحی سایبان با استفاده از یادگیری ماشین، ارائه می‌دهد، چندین مسیر برای تحقیقات آتی وجود دارد که می‌تواند درک ما را از این موضوع بالاتر ببرد:

• آزمایش در دنیای واقعی:

- مطالعه حاضر بر اساس داده‌های شبیه‌سازی است. تحقیقات آینده باید این یافته‌ها را از طریق آزمایش در دنیای واقعی، جایی که طرح‌های سایبان در واحدهای مسکونی واقعی اجرا می‌شوند و نفوذ نور خورشید در شرایط واقعی اندازه‌گیری می‌شود، اعتبار سنجی کنند. این امر به تأیید کاربرد عملی مدل‌های توسعه یافته در این مطالعه کمک می‌کند.

• تحلیل خاص آب و هوا:

- این مطالعه بر روی یک آب و هوای خاص (اصفهان) متمرکز شده است. تحقیقات آینده می‌تواند بررسی کند که چگونه پارامترهای طراحی سایبان بر نفوذ نور خورشید در شرایط آب و هوایی مختلف، مانند آب و هوای گرم و مرطوب یا مناطق سرد، تأثیر می‌گذارد. این امر دستورالعمل‌های طراحی تعمیم‌یافته‌تری را ارائه می‌کند که می‌تواند در طیف وسیع‌تری از محیط‌ها اعمال شود.

• ادغام با مدل‌های انرژی ساختمان:

- مطالعات آینده می‌تواند بهینه‌سازی طراحی سایبان را با مدل‌های انرژی ساختمان برای ارزیابی تأثیر کلی بر بهره‌وری انرژی، از جمله بارهای گرمایشی، سرمایشی و روشنایی ادغام کند. این امر درک جامع‌تری از چگونگی کمک طرح‌های سایبان به عملکرد کلی انرژی ساختمان‌های مسکونی ارائه می‌دهد.

• تکنیک‌های پیشرفته یادگیری ماشین:

- درحالی که این مطالعه از مدل‌های یادگیری ماشین سنتی استفاده کرده است، تحقیقات آینده می‌تواند استفاده از تکنیک‌های پیشرفته‌تر، مانند یادگیری تقویتی یا شبکه‌های مولد تخاصمی (GANs) را برای بهینه‌سازی طرح‌های سایبان بررسی کند. این روش‌ها می‌توانند به طور بالقوه

روابط پیچیده‌تری را بین پارامترهای طراحی و نفوذ نور خورشید کشف کنند.

نتیجه‌گیری

این مطالعه اثربخشی یادگیری ماشین را در بهینه‌سازی طرح‌های سایبان برای به حداکثر رساندن نفوذ نور خورشید در واحدهای مسکونی نشان داد. مدل رگرسیون جنگل تصادفی به عنوان قابل اعتمادترین ابزار برای پیش‌بینی میانگین نور دریافتی (۷۱) ظاهر شد و بینش‌های ارزشمندی را در مورد روابط بین عمق، فاصله و تعداد سایبان‌ها ارائه داد. یافته‌ها نشان می‌دهد که فاصله بین سایبان‌ها مهم‌ترین عامل است؛ درحالی‌که عمق و تعداد سایبان‌ها تأثیر منفی بر نفوذ نور خورشید، به‌ویژه در پیکربندی‌های عمودی دارند. توصیه‌های عملی ارائه شده در این مطالعه می‌تواند معماران و طراحان را در ایجاد طرح‌های سایبان موثرتر که تعادل بین نیازهای سایه و نور روز را برقرار می‌کنند، راهنمایی کند. تحقیقات آینده باید بر روی آزمایش در دنیای واقعی، تحلیل خاص آب و هوا، و ادغام تکنیک‌های پیشرفته یادگیری ماشین برای ارتقای درک ما از بهینه‌سازی طراحی سایبان متمرکز شود. با بهره‌گیری از این بینش‌ها، طراحان می‌توانند فضاهای زندگی کم‌مصرف‌تر و راحت‌تری ایجاد کنند و به اهداف گسترده‌تر معماری پایدار کمک کنند.

منابع

- Yi, H., Kim, M.-J., Kim, Y., Kim, S.-S., & Lee, K.-I. (2019). Rapid Simulation of Optimally Responsive Façade during Schematic Design Phases: Use of a New Hybrid Metaheuristic Algorithm. *Sustainability*, 11(9), 2681. <https://doi.org/10.3390/su11092681>
- Xie, Y., Ji, W., Li, T., Liang, Y., & Li, F. (2019). Location Aided and Machine Learning-Based Beam Allocation for 3D Massive MIMO Systems. 2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC), 836-841. <https://doi.org/10.1109/IWCMC.2019.8766724>.
- Wagle, S., & Paranjape, A. (2020). Use of Simulation-Aided Reinforcement Learning for Optimal Scheduling of Operations in Industrial Plants. 2020 Winter Simulation Conference (WSC), 572-583. <https://doi.org/10.1109/WSC48552.2020.9383893>.
- Nourkojouri, H., Shafavi, N., Tahsildoost, M., & Zomorodian, Z. (2021). Development of a Machine-Learning Framework for Overall Daylight and Visual Comfort Assessment in Early Design Stages. *Journal of Daylighting*. <https://doi.org/10.15627/jd.2021.21>.
- Nourkojouri, H., Shafavi, N., Tahsildoost, M., & Zomorodian, Z. (2021). Development of a Machine-Learning Framework for Overall Daylight and Visual Comfort Assessment in Early Design Stages. *Journal of Daylighting*. <https://doi.org/10.15627/jd.2021.21>.
- Ghritli, R., Okano, Y., Inatomi, Y., & Dost, S. (2022). Control of growth interface shape during InGaSb growth by vertical gradient freezing under microgravity, and optimization using machine learning. *Japanese Journal of Applied Physics*, 61. <https://doi.org/10.35848/1347-4065/ac99c2>.
- Zhao, R., Wang, X., Wei, Y., He, X., & Xu, H. (2024). Machine Learning Applied to Electron Beam Lithography to Accelerate Process Optimization of a Contact Hole Layer.. *ACS applied materials & interfaces*. <https://doi.org/10.1021/acsami.3c18889>.
- Gupta, V., Solomou, A., Limaye, P., Becker, G., Abinesh, M., Meier, H., Valiveti, D., Sun, H., Amalokwu, K., Crawford, B., Manchanda, R., & Kulkarni, K. (2023). A Machine Learning Based Proxy Model for the Rapid Prediction of Hydraulic Fractures. *All Days*. <https://doi.org/10.56952/arma-2023-0315>.
- Mahmood, M., Khraisheh, M., Popescu, A., & Liou, F. (2024). Processing windows for Al-357 by LPBF process: a novel framework integrating FEM simulation and machine learning with empirical testing. *Rapid Prototyping Journal*. <https://doi.org/10.1108/rpj-01-2024-0057>.
- Mohammed, A., Tariq, M. A. U. R., Ng, A. W. M., Zaheer, Z., Sadeq, S., Mohammed, M., & Mehdizadeh-Rad, H. (2022). Reducing the Cooling Loads of Buildings Using Shading Devices: A Case Study in Darwin. *Sustainability*, 14(7), 3775. <https://doi.org/10.3390/su14073775>
- Jakubiec, J. A., & Reinhart, C. F. (2012). The 'adaptive zone' – A concept for assessing discomfort glare throughout daylight spaces. *Lighting Research & Technology*, 44(2), 149-170.
- Najafi, Ahmad. Rahravi-Poodeh, Sanaz. Tadayon, Bahareh. (2023). Optimizing Window Design for Sustainable Daylighting in the Residential Buildings of Isfahan. *Contemporary Urban and Architectural Heritage Research Quarterly*. 1(1). 131-146
- Papadopoulos, S., Woon, W.L., Azar, E. (2018). Machine Learning as Surrogate to Building Performance Simulation: A Building Design Optimization Application. In: Woon, W., Aung, Z., Catalina Feliú, A., Madnick, S. (eds) *Data Analytics for Renewable Energy Integration. Technologies, Systems and Society. DARE 2018. Lecture Notes in Computer Science()*, vol 11325. Springer, Cham. https://doi.org/10.1007/978-3-030-04303-2_7
- Reinhart, C. F., & Walkenhorst, O. (2001). Validation of dynamic RADIANCE-based daylight simulations for a test office with external blinds. *Energy and Buildings*, 33(7), 683-697.
- Al-Tamimi, N. A. M., & Fadzil, S. F. S. (2011). The potential of shading devices for temperature reduction in high-rise residential buildings in the tropics. *Procedia Engineering*, 21, 273-282.
- Tzempelikos, A., & Athienitis, A. K. (2007). The impact of shading design and control on building cooling and lighting demand. *Solar Energy*, 81(3), 369-382.