

مروری بر کاربرد الگوریتم‌های یادگیری ماشین در پیش‌بینی عملکرد انرژی ساختمان

تاریخ دریافت: ۱۴۰۰/۱۱/۱۷

تاریخ پذیرش: ۱۴۰۱/۰۲/۰۲

کد مقاله: ۱۶۶۱۰

سحر لبافان^۱

چکیده

امروزه به دلیل افزایش اهمیت مصرف انرژی، روش‌های بسیاری با هدف پیش‌بینی دقیق میزان مصرف انرژی مورد استفاده قرار گرفته است. یکی از این روش‌ها استفاده از هوش مصنوعی است. برای انجام این کار از الگوریتم‌های مختلفی استفاده می‌شود که می‌توانند نتیجه دقیق‌تری نسبت به سایر ابزارهای شبیه‌سازی انرژی ساختمان ارائه دهند. این مقاله، با هدف شناسایی دقیق‌ترین و پرکاربردترین الگوریتم‌ها، تعدادی از تحقیقات مرتبط با این موضوع که در سال‌های اخیر انجام شده‌اند را بررسی می‌کند. الگوریتم‌هایی که دارای کمترین میزان خطا، بیشترین سرعت و دقت محاسبات هستند. پس از استفاده از الگوریتم‌های مختلف، نقاط قوت و ضعف هر یک مشخص می‌شود. در این تحقیق، از چارچوب لایه‌ای برای انتخاب مقالات استفاده شده است. در لایه اول، سال انتشار مقاله مورد توجه بوده؛ دوم، دارای کلمات کلیدی مرتبط و مطابق با دستاوردهای تحقیق بوده‌اند و سوم، مطابقت با موضوع مقاله بررسی شده است. هدف این مقاله شناخت بهتر ویژگی‌های الگوریتم‌های مختلف با توجه به نوع استفاده از آنها است؛ علاوه بر این، بهترین و پرکاربردترین الگوریتم‌های یادگیری ماشین در سال‌های اخیر معرفی می‌شوند. الگوریتم‌های پرکاربرد برای بهینه‌سازی مصرف انرژی و پیش‌بینی عملکرد انرژی ساختمانها به ترتیب شبکه عصبی مصنوعی^۲، ماشین بردار پشتیبان^۳، جنگل تصادفی^۴، الگوریتم ژنتیک^۵ و رگرسیون خطی^۶ بوده است.

واژگان کلیدی: الگوریتم‌های یادگیری ماشین، پیش‌بینی انرژی، عملکرد انرژی، بازده انرژی ساختمان، دقت نتایج

۱- کارشناسی ارشد معماری و انرژی، دانشگاه معماری و هنر پارس، تهران، ایران sahar.labafan@pu.ac.ir


- 2 . Artificial Neural Network (ANN)
- 3 . Support Vector Machine (SVM)
- 4 . Random Forest (RF)
- 5 . Genetic Algorithm (GA)
- 6 . Linear Regression (LR)

۱- مقدمه

سهم جهانی ساختمان‌ها در مصرف انرژی دائماً در حال افزایش است و اکنون بین ۲۰ تا ۴۰٪ می‌باشد و تقریباً ۳/۱ درصد از انتشار گازهای گلخانه‌ای مربوط به آنهاست. پیش‌بینی و طبقه‌بندی مصرف انرژی ساختمان‌ها با هدف بهبود عملکرد آنها، کاهش اثرات زیست محیطی و برآورد پتانسیل اقتصادی به منظور صرفه‌جویی در مصرف انرژی و ایجاد برنامه‌های مرتبط با استفاده از انرژی‌های تجدیدپذیر امری ضروری است. (Wei et al. 2018) رویکردهای متداول در شبیه سازی انرژی ساختمان به شرح زیر دسته بندی می شود:

۱. رویکردهای مبتنی بر جعبه سفید، ۲. رویکردهای مبتنی بر جعبه خاکستری، ۳. رویکردهای مبتنی بر جعبه سیاه.^۱ رویکردهای مبتنی بر جعبه سفید مرتبط با فیزیک ساختمان هستند و به اطلاعات دقیق در مورد بدنه ساختمان نیاز دارند. بنابراین در بسیاری از موارد که پیش بینی مصرف انرژی دارای محاسبات پیچیده است، از این روش استفاده می‌شود. با توجه به این موضوع، این روش اخیراً ساده سازی شده و این ساده سازی منجر به وقوع اشتباهاتی در نتایج شده است؛ در این روش معمولاً میزان صرفه جویی در مصرف انرژی بیش از حد واقعی ارزیابی می‌شود. (Barnaby and Spitler 2005) (Cavalheiro and Carreira 2016)

رویکردهای مبتنی بر جعبه خاکستری، رویکرد جعبه سفید اصلاح شده است؛ به این معنی که از روش‌های آماری برای ترکیب اطلاعات تاریخی و فیزیکی ساختمان در شبیه سازی مصرف انرژی استفاده می‌کند. با توجه به اینکه ورودی‌ها در این روش مشخص نیستند، یکی از مشکلات نسخه فعلی جعبه خاکستری ناکارآمدی محاسباتی است. برای جبران کاستی‌های رویکرد جعبه سفید و خاکستری، رویکردهای مبتنی بر جعبه سیاه توسعه یافته‌اند که فقط با استفاده از داده‌های تاریخی می‌توانند مصرف انرژی ساختمان را تجزیه و تحلیل کنند و در این روش نیازی به اطلاعات فیزیکی ساختمان نیست. این تغییر اساسی باعث شده است که رویکرد مبتنی بر جعبه سیاه با محاسبات سریع و دقیق بهتر از جعبه سفید و خاکستری عمل کند. (Zhao and Magoulès 2012)



دیاگرام ۱) تکنیک‌های مدلسازی و پیش بینی مصرف انرژی ساختمان (Bourdeau et al. 2019)

دیاگرام ۱ طبقه بندی الگوریتم‌ها را بر اساس داده‌های ورودی نشان می‌دهد. در این مقاله، روش‌های منفرد مورد بحث قرار گرفته و روش‌های ترکیبی در محدوده این پژوهش نیستند. با توجه به الگوریتم آماری و استفاده زیاد از داده‌ها، رویکردهای مبتنی بر جعبه سیاه به عنوان رویکردهای داده محور نیز شناخته می‌شوند. (Wei et al. 2018)

۲- روش تحقیق

در این تحقیق ابتدا در مورد تکنیک‌ها و الگوریتم‌های یادگیری ماشین «بدون نظارت» و «تحت نظارت» مختصراً توضیح داده شده است. سپس انواع الگوریتم‌های یادگیری ماشین تحت نظارت معرفی می‌شوند. برای این کار، تعدادی از مقالات مرتبط با

1. White box based approaches, 2.Grey box-based approaches, 3.Black box based approaches

موضوع «پیش بینی و بهینه سازی مصرف انرژی ساختمان» انتخاب شده که در آن‌ها از الگوریتم‌های هوش مصنوعی و یادگیری ماشین برای پیش‌بینی یا بهینه سازی مصرف انرژی استفاده شده است.

در این تحقیق، از چارچوب لایه‌ای برای انتخاب مقالات استفاده شده است. در لایه اول، مقالاتی که در سالهای اخیر منتشر شده‌اند مورد بررسی قرار گرفته‌اند؛ در لایه دوم، مقالات انتخابی دارای کلمات کلیدی مرتبط مورد نظر بوده و مطابق با دستاوردهای تحقیق بوده‌اند؛ در لایه سوم، مطابقت موضوع مقاله اهمیت داشته و در آن‌ها از الگوریتم‌های یادگیری ماشین برای پیش‌بینی یا بهینه سازی مصرف انرژی ساختمان استفاده شده است. کاربرد، نقاط قوت و ضعف تکنیک‌های یادگیری ماشین که در مقالات منتخب ذکر شده است، در این مطالعه بررسی می‌شوند. هدف از این مطالعه شناخت بهتر تکنیک‌های یادگیری ماشین برای پیش‌بینی یا بهینه سازی انرژی در ساختمان‌ها در مطالعات آینده است.

۲-۱- تکنیک‌ها و الگوریتم‌های یادگیری ماشین بدون نظارت

در یادگیری بدون نظارت، فقط داده‌های ورودی (X) وجود دارند و متغیر خروجی مربوطه وجود ندارد. هدف از یادگیری بدون نظارت، مدلسازی ساختار داده‌ها برای کسب اطلاعات بیشتر در مورد آنها است. دلیل نامگذاری "یادگیری بدون نظارت" این است که برخلاف یادگیری تحت نظارت، هیچ پاسخ یا مشاهده‌گر صحیحی وجود ندارد. یادگیری بدون نظارت به طرح الگوریتم‌هایی برای ارائه ساختار داده متکی است. مشکلات یادگیری ماشین بدون نظارت بیشتر مربوط به خوشه‌بندی و مسائل مربوط به آن است. (ترابی ۱۳۹۹)

خوشه‌بندی^۱: خوشه‌بندی هنگامی استفاده می‌شود که هدف کشف ماهیت داده‌ها باشد، مثلاً وقتی مشتری‌ها بر اساس نوع خریدشان دسته‌بندی می‌شوند.

ارتباط^۲: یکی از موضوعات مهم هنگام تجزیه و تحلیل داده‌ها، کشف قوانینی است که بخش بزرگی از داده‌های ما را توصیف می‌کند. مانند این مثال؛ افرادی که مایل به خرید A هستند، مایل به خرید B نیز هستند. (ترابی ۱۳۹۹)

پر کاربردترین الگوریتم‌های یادگیری ماشین بدون نظارت عبارتند از:

- K-means برای مشکلات خوشه بندی
- الگوریتم Apriori برای مشکلات یادگیری قاعده ارتباط.

۲-۲- تکنیک‌ها و الگوریتم‌های یادگیری ماشین تحت نظارت

غالباً در آموزش‌های عملی ماشینی از یادگیری نظارت شده استفاده می‌شود. در یادگیری تحت نظارت، چندین متغیر ورودی (X) و یک متغیر خروجی (Y) وجود دارد و می‌توان از الگوریتمی برای یادگیری عملکرد نگاشت از ورودی به خروجی $Y = f(X)$ استفاده کرد. هدف از بکارگیری الگوریتم، تخمین دقیق عملکرد نقشه برداری است؛ تا زمانی که ورودی جدیدی به آن داده شود، می‌تواند متغیرهای خروجی را به درستی پیش‌بینی کند. دلیل نامگذاری "یادگیری تحت نظارت" این است که فرایند یادگیری الگوریتم با استفاده از داده‌های آموزشی می‌تواند مانند یک معلم ناظر بر روند یادگیری باشد. به گونه‌ای که الگوریتم داده‌های آموزشی را به طور مکرر پیش‌بینی می‌کند و آموزش می‌دهد؛ سپس توسط معلم اصلاح می‌شود. به این ترتیب از ابتدا، ما جواب صحیح آزمون را می‌دانیم. وقتی عملکرد الگوریتم به سطح قابل قبولی رسید، یادگیری متوقف می‌شود. رگرسیون و طبقه‌بندی دو مشکل یادگیری تحت نظارت هستند:

- طبقه بندی: هنگامی که متغیر خروجی یک دسته باشد. مثل قرمز و آبی، یا بیماری و عدم بیماری.
 - رگرسیون: هنگامی که متغیر خروجی یک مقدار واقعی مانند دلار یا وزن است.
- برخی از مشکلات متداول ایجاد شده در طبقه‌بندی و رگرسیون^۳ به ترتیب شامل نظریه و پیش بینی سری زمانی^۴ هستند (Jason Brownlee 2016)
- الگوریتم‌های یادگیری ماشین تحت نظارت، پیش‌بینی خروجی را از داده‌های ورودی یاد می‌گیرند و همه ورودی‌ها دارای برچسب هستند. (Jason Brownlee 2016)

از جمله محبوب‌ترین مدل‌های پیش‌بینی داده محور یا الگوریتم‌های یادگیری ماشین تحت نظارت، شبکه‌های عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM)، رگرسیون آماری، درخت تصمیم (DT) و الگوریتم ژنتیک (GA) هستند. در این بخش هر یک از این مدل‌ها به طور خلاصه معرفی می‌شوند.

1 . Clustering
2 . Association
3 . Classification and Regression
4 . Recommendation and time series prediction

۳-۲- شبکه‌های عصبی مصنوعی

در طراحی شبکه‌های عصبی مصنوعی از ساختار مغز انسان الهام گرفته شده است و واحد پردازش مدل سازی و عنصر اصلی آن یک نورون بیولوژیکی است. به طور کلی یک شبکه، از واحدهای فرایندی بسیاری تشکیل شده است که به صورت لایه لایه هستند و در لایه‌های مختلف، واحدهای پردازشی به یکدیگر متصل می‌شوند. (Wei et al. 2018) این شبکه از سه لایه از نورون‌های بهم پیوسته تشکیل شده است: لایه ورودی، لایه پنهان و لایه خروجی. کار و توانایی اصلی شبکه عصبی مصنوعی ایجاد ارتباط بین لایه‌های مختلف سلول‌های عصبی تعریف شده است. وزن این اتصال از فرایند یادگیری گرفته شده و تابع فعال‌سازی وزن ورودی نورون‌ها را به خروجی فعال سازی تبدیل می‌کند. (AlTabbaa and Ankrah 2016)

۴-۲- ماشین بردار پشتیبان

این روش با تعداد n داده سروکار دارد و به طور گسترده‌ای برای حل مشکلات رگرسیون مورد استفاده قرار می‌گیرد تا رابطه بین ورودی‌های غیر خطی با یک هدف مشترک با مقداری واقعی تخمین زده شود. هنگامی که ماشین بردار پشتیبان به عنوان رگرسیون مورد استفاده می‌گیرد، با عنوان «رگرسیون بردار پشتیبانی» شناخته می‌شود. ماشین بردار پشتیبان مبتنی بر داده به یکی از پرکاربردترین روش‌ها برای پیش‌بینی مصرف انرژی ساختمان تبدیل شده است. (Wei et al. 2018) ماشین بردار پشتیبان به گونه‌ای انعطاف‌پذیر پیچیدگی مدل و الگوی پراکنده راه حل‌ها را کنترل می‌کند. انگیزه اصلی این الگوریتم جستجوی بهینه‌ترین مرزهای تعمیم در راستای هدف رگرسیون است. (Drucker et al. 1996)

۵-۲- رگرسیون خطی

این روش شناخته شده و معمول بیشتر برای مدل‌های پیش‌بینی استفاده می‌شود. رگرسیون خطی به راحتی قابل استفاده است و پارامترهای مدل را به راحتی درک می‌کند. رگرسیون یک معادله ایجاد شده از داده‌های ورودی را برای پیش‌بینی خروجی به عنوان یک تابع خطی ایجاد می‌کند. پیش‌بینی مصرف انرژی ساختمان برای ایجاد رابطه و پیوند خروجی با آن به تحلیل رگرسیون متکی است. از رگرسیون آماری برای پیش‌بینی مصرف انرژی ساختمان استفاده می‌شود. (AlTabbaa and Ankrah 2016)

"رگرسیون خطی" یک الگوریتم معمول و بصری برای یک مدل پیش‌بینی کلی است. هدف رگرسیون خطی ساده تبیین رابطه بین یک متغیر وابسته و مجموعه‌ای از متغیرهای مستقل با استفاده از ترکیبات خطی مورد بعدی است. تابع هدف برای ساخت یک مدل رگرسیون خطی ساده، به حداقل رساندن مجموع حداقل خطاهای مربع است. (Deng, Fannon, and Eckelman 2018)

۶-۲- درخت تصمیم‌گیری

درخت تصمیم‌گیری روشی برای دسته‌بندی داده‌ها به شکل یک نمودار درختی است. یک مدل درخت تصمیم‌گیری از یک گره ریشه و چندین گره شاخه تشکیل شده است؛ نقطه شروع نمودار از گره ریشه است. گره ریشه از داده‌های ورودی شروع می‌شود و این داده‌ها با توجه به برخی متغیرهای پیش‌بینی که قبلاً به عنوان «معیار تقسیم بندی» تعریف شده‌اند، به گروه‌های مختلف تقسیم می‌شوند. داده‌های تقسیم شده شاخه‌های ریشه هستند و هر گره زیر مجموعه دیگری دارد. گره‌های فرعی یا به شاخه‌های بیشتری تقسیم می‌شوند یا بدون گره‌های فرعی باقی می‌مانند. آخرین شاخه هیچ زیر شاخه‌ای ندارد. (Wei et al. 2018)

۷-۲- جنگل تصادفی

به عنوان یک پیشرفت در روش معمول طبقه بندی و رگرسیون^۲، جنگل تصادفی یک روش مجموعه درختی است که تعداد زیادی درخت تصمیم‌گیری را به طور موازی رشد می‌دهد تا همزمان واریانس و تمایلات به یک سمت را در مدل کاهش دهد. (Breiman 2001)

۸-۲- الگوریتم‌های ژنتیک

1 . Support Vector Regression (SVR)
2 . Classification and Regression Tree (CART)

یک روش بهینه سازی تصادفی است که با الهام از تکامل طبیعی و مبتنی بر ایده "بقا از بهترین" ساخته شده است. در الگوریتم ژنتیک، یک فضای جستجو توسط مجموعه‌های مختلف وزن ایجاد می‌شود که یک نقطه از آن نشان دهنده یک راه حل عملی برای مسئله مورد بررسی است. وظیفه اصلی الگوریتم ژنتیک مدل سازی یک فرایند تکاملی برای معرفی بهترین راه حل‌های عملی در این فضا است. (Lucasius and Kateman 1993)

۳- بررسی مقالات پژوهشی

تعدادی از مقالات منتشر شده در سال‌های اخیر که از الگوریتم‌های هوش مصنوعی و یادگیری ماشین برای پیش بینی یا بهینه سازی مصرف انرژی ساختمان استفاده کرده‌اند، در این مطالعه بررسی شده‌اند. همانطور که قبلاً ذکر شد، از چارچوب لایه‌ای برای انتخاب این مقالات استفاده شده است. مقالات منتخب با اهداف و رویکردهای مختلف در کشورهای مختلف انجام شده‌اند؛ همچنین در هر یک از آنها از روشی خاص و منحصر به فرد برای انجام کار استفاده شده است. تنها وجه مشترک آنها استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین برای اهداف معماری و انرژی است. در ادامه، نقاط قوت و ضعف ذکر شده در هر مقاله و مربوط به هر الگوریتم را با اهداف خاص آن تحلیل خواهیم کرد. در مقالات منتخب، الگوریتم‌های یادگیری ماشین مطابق با اهداف پژوهشگران به چالش کشیده شده‌اند و نقاط قوت و ضعف آنها در نتایج این تحقیقات آورده شده است.

۴- پیش بینی، بهینه سازی، پیشنهاد روش و ارزیابی

مطابق جدول ۱، که در آن فقط مقالاتی بررسی شده‌اند که هدف اصلی آنها "پیش بینی" (برق، گاز، گرمایش، سرمایش و غیره) بوده است؛ نتیجه گیری می‌شود که در حدود ۵۰٪ از تحقیقات برای دستیابی به هدف خود از ترکیب الگوریتم‌ها (دو الگوریتم یا بیشتر) استفاده کرده‌اند و ۵۰٪ دیگر فقط از یک الگوریتم استفاده کرده‌اند. علاوه بر این، در بیشتر تحقیقات از الگوریتم ANN استفاده شده است و مسئله اصلی ذکر شده در آنها، بهبود عملکرد این الگوریتم به روش‌های مختلف بوده است. در مقالات بررسی شده در جدول ۱، عمدتاً اهداف به ترتیب مربوط به پیش بینی مصرف انرژی و سپس مصرف برق می‌باشد. این اهداف، اهمیت این مسئله را در سطح جهانی نشان می‌دهد. با توجه به این نکته که بیش از ۴۰٪ انرژی مصرفی جهان به ساختمانها تعلق دارد. (SVM (Hwang, Suh, and Otto 2020) دارای تعدادی پارامتر است که با افزایش خطی تعداد متغیرهای ورودی به صورت خطی افزایش می‌یابد. از طرف دیگر، ANN این ویژگی را ندارد. یک شبکه عصبی قادر است تعداد لایه‌های مورد نظر شما را داشته باشد. ("SVM Vs Neural Network | Baeldung on Computer Science" n.d.)

طبق جدول ۲، که در آن فقط مقالاتی بررسی شده‌اند که هدف اصلی آنها "بهینه سازی" (مصرف انرژی) بوده است؛ نتیجه گیری می‌شود که باز هم ANN، در مواردی که تحقیقات با اهداف مختلف مرتبط با تعیین عملکرد بهینه سازی با روش‌های متعدد انجام شده‌اند، بیشتر مورد استفاده قرار گرفته است؛ حتی اگر بتوان تکنیک‌های دیگری را برای حل مشکلات بهینه سازی بکار برد. (Villarrubia et al. 2018)

مطابق جدول ۳، که در آن فقط مقالاتی بررسی شده‌اند که هدف اصلی آنها "پیشنهاد روش" بوده است؛ نتیجه‌گیری می‌شود که روش‌های پیشنهادی جدید بیشتر در رابطه با بهینه سازی و پیش بینی مصرف انرژی هستند. ابتدا از الگوریتم پایه استفاده شده و سپس تغییرات و روش‌های جدیدی بر روی آن اعمال شده است. در نهایت، روش جدید با الگوریتم پایه مقایسه می‌شود. علاوه بر این، بیشتر الگوریتم‌های مدرن یادگیری ماشین دارای پارامترهایی هستند که میبایست قبل از استفاده و اجرا اصلاح شوند. به چنین پارامترهایی «ابر پارامتر» گفته می‌شود. در بسیاری از موارد، عملکرد یک الگوریتم در یک کار خاص به تنظیمات ابر پارامتر آن بستگی دارد. با هدف دستیابی به بهترین عملکرد، متخصصان یادگیری ماشین می‌توانند ابر پارامترها را تنظیم کنند. (Weerts, Müller, and Vanschoren 2020)

جدول ۴ مقالاتی را با موضوع "ارزیابی" ارائه می‌دهد و بیشتر به مقایسه عملکرد الگوریتم‌های مختلف برای دستیابی به یک هدف واحد می‌پردازد.

جدول ۱. تجزیه و تحلیل کاربرد الگوریتم‌ها به منظور "پیش‌بینی"، در مقالات منتخب

شماره	منبع / تاریخ	الگوریتم	متغیر وابسته	نقاط ضعف (و راه‌حل‌ها)	نقاط قوت
۱	(Bui et al. 2020)	الگوریتم کرم شب تاب مبتنی بر الکترومغناطیس با شبکه عصبی مصنوعی (EFA-ANN)	پیش‌بینی بار سرمایشی و گرمایشی	الگوریتم EFA-ANN (ساخته شده است)؛ EFA با ANN ترکیب شده تا با بهینه‌سازی مجموعه پارامترهای اولیه، عملکرد خود را بهبود بخشد.	با استفاده از الگوریتم-EFA (ANN)، نتایج پیش‌بینی مصرف سرمایش و گرمایش به طور دقیق و سریع انجام شد. محاسبات نیز سریع انجام شد.
۲	(Walker et al. 2020)	Boosted-tree – RF – SVM-linear – Quadratic – Cubic – Fine-Gaussian – ANN –	پیش‌بینی مصرف برق در ساختمان‌های منفرد و غیر منفرد با استفاده از تعدادی الگوریتم یادگیری ماشین برای ۴۷ ساختمان اداری با استفاده از داده‌های آنها	الگوریتم ANN در مقایسه با الگوریتم‌های درخت رگرسیون، نتایج دقیقی در مدل آموزشی ارائه نداده است.	سه الگوریتم boosted-tree، RF و شبکه ANN از نظر زمان محاسبه و دقت خطا عملکرد خوبی داشته‌اند. در میان الگوریتم‌های رگرسیون در نظر گرفته شده، RF بهترین نتیجه را ارائه داده‌اند.
۳	(Luo, Oyedele, Ajayi, Akinade, Delgado, et al. 2020)	genetic algorithm-determined deep feedforward neural network architecture (GA-DFNN)	پیش‌بینی مصرف برق به دو صورت ساعتی در روزهای آینده و روزانه در هفته‌های آینده برای ساختمان یک دانشگاه در انگلستان	نتایج الگوریتم ساخته شده (شبکه) نشان می‌دهد که، وقتی تعداد لایه‌های پنهان بسیار کم باشد، خطاهای زیادی وجود دارد.	مدلی که برای پیش‌بینی ساخته شده است، عملکرد بهتری نسبت به تمام الگوریتم‌های مرجع دارد.
۴	(Chai et al. 2020)	از الگوریتم‌های ANN برای پیش‌بینی TCV و TSV در ساختمانهای مسکونی که دارای تهویه طبیعی هستند استفاده شده است.	ارزیابی راحتی حرارتی (در فضای داخلی)	مدل مناسب باید بر اساس داده‌های محلی ایجاد می‌شد. دامنه دما در ساختمانهای دارای تهویه طبیعی بسیار گسترده‌تر از منطقه آسایش سازگار ASHRAE بوده است.	در مقایسه با مدل‌های تعادل حرارتی سنتی، شبکه عصبی دارای عملکرد بهتری بوده است.
۵	(Luo, Oyedele, Ajayi, Akinade, Owolabi, et al. 2020)	DNN هر کدام دارای یک مشخصه آب و هوایی، همراه با مصرف انرژی در ساختمان و زمان مربوطه، برای آموزش یک زیر مدل DNN	ارائه یک رویکرد مبتنی بر هوش مصنوعی یکپارچه که دارای ویژگی‌هایی مانند بهینه‌سازی تکاملی و مدل DNN تطبیقی برای پیش‌بینی مصرف انرژی ساعتی در هفته‌های آینده باشد.	مدل پیشنهادی GA-DNN می‌تواند در آینده اصلاح شود. همچنین می‌توان برای حل مشکل احتمالی ناشی از وجود داده‌های ناقص اندازه‌گیری به دلیل خطاهای سنسور و تجهیزات، اصلاحات بیشتری انجام داد.	مدل DNN تطبیقی ابداع شده می‌تواند مصرف ساعتی دقیق را در هفته‌های آتی و برای سیستم مدیریت انرژی ساختمان پیش‌بینی کند.
۶	(Chakraborty, Elzarka, and Bhatnagar 2016)	SVM	با استفاده از یک مجموعه داده معتبر حاوی داده‌های تاریخی تابش خورشیدی، یک روش مدل ترکیبی بر اساس SVR و برآورد احتمال برای پیش‌بینی متغیرهای اقلیمی ارائه شده است.	– بسیاری از پارامترها برای جلوگیری از مشکل کم‌برازش و بیش‌برازش ۱ انتخاب شده اند. – روش پیشنهادی تنها با پیش‌بینی داده‌های تابش خورشید معتبر است.	مزیت عمده SVR نسبت به سایر روشهای رگرسیون این است که از نظر نظری بسیار قوی است و توسط نظریه یادگیری آماری ایجاد می‌شود، دقت بلندمدت روش مدل سازی پیشنهادی معتبرتر از روش فعلی است.
۷	(Kallio et al. 2021)	-Ridge regression -Decision Tree -Random Forest -Multilayer Perceptron	پیش‌بینی غلظت آینده CO2 در فضاهای داخلی	استفاده از یک مدل داده پیچیده تر، مانند RF یا MLP، ارزش افزوده قابل توجهی در این مطالعه ندارد	DT می‌تواند تقریباً به اندازه محاسبات سنگین تر مدل جنگل تصادفی دقیق باشد.
۸	(Deng, Fannon, and Eckelman 2018)	- LR - Lasso Regression - SVM - RF - Gradient	برآورد EUI برای ساختمانهای اداری تجاری در ایالات متحده و مصرف نهایی انرژی فردی براساس	هیچ یک از متغیرها برای پیش‌بینی‌های انرژی زیر سیستم کل و HVAC پررنگ نیستند زیرا همه آنها با استفاده از RF به طور	برای پیش‌بینی EUI کل، RF و SVM در میان همه بخشهای مجموعه داده و دیگر الگوریتم‌ها دارای عملکرد برتر بوده‌اند.

ردیف	منبع / تاریخ	الگوریتم	متغیر وابسته	نقاط ضعف (و راه حل‌ها)	نقاط قوت
		Boosting - ANN	جدیدترین داده‌های CBECS 2012.	میانگین کمتر از ۲۰ درصد کاهش دقت دارند.	
۹	(Seyedzadeh et al. 2018)	ANN SVM Gaussian-based regressions Clustering همه مدل‌ها با تهیه تعداد زیادی نمونه و بهینه سازی پارامترها، دقت قابل قبولی را ارائه می‌دهند.	پیش بینی مصرف انرژی و عملکرد ساختمان	هیچ تضمینی برای عملکرد مدل‌ها وجود ندارد. نتایج نشان می‌دهد که شبکه ANN باید با تعداد کافی نمونه تغذیه شود تا دقت قابل قبولی را ارائه دهد. در غیر این صورت ممکن است با یک مدل ساده MLR عملکرد بهتری بدست آید.	SVM و GP با تعداد کمی پارامتر نظارت می‌شوند و عملکرد مطلوبی را نیز ارائه می‌دهند. SVM در پیش بینی بار از ANN پیشی می‌گیرد و قابلیت ساخت مدل از نمونه‌های محدود را دارد. ANN بار کوتاه مدت را سریع و دقیق پیش بینی می‌کند. در صورتیکه در متغیرهای ورودی عدم قطعیت وجود داشته باشد، GP برای برآورد انرژی درازمدت مناسب‌تر است.
۱۰	(Kim, Kim, and Srebric 2020)	LR و ANN با Levenberg Marquardt Back Propagation (LM-BP) ارزیابی چگونگی تاثیرگذاری نرخ اشغال فضا و شرایط محیطی محلی بر مصرف برق	پیش بینی مصرف برق یک ساختمان؛ مقایسه رویکردهای پیش بینی انرژی الکتریکی ساختمان با روش آماری رایج: الگوریتم‌های LR و ANN	الگوریتم ANN پیشنهادی را می‌توان با پارامترهای اضافی به منظور بهبود دقت پیش بینی‌ها در آینده به روز کرد.	در مقایسه با مدل رگرسیون خطی برای پیش بینی مصرف برق یک ساختمان، از روش ANN پیشنهادی می‌توان به عنوان یک روش قابل اعتماد استفاده کرد.
۱۱	(Li et al. 2018)	ترکیبی از شبکه‌های عصبی مصنوعی (ANN) با الگوریتم بهبود یافته بهینه سازی مبتنی بر آموزش و یادگیری (TLBO)	پیش بینی مصرف انرژی الکتریکی ساعتی از دو ساختمان آموزشی واقع در ایالات متحده آمریکا و چین	برای بهبود دقت مدل ANN در پیش بینی کوتاه مدت انرژی ساختمان، از روش ترکیبی جدیدی به نام TLBO-ANN برای بهینه سازی پارامترهای ANN در محدوده جهانی استفاده شده است.	مدل‌های پیشنهادی، پتانسیل بالایی برای پیش بینی انرژی مصرفی در ساختمان به صورت آنلاین دارند.

جدول ۲. تجزیه و تحلیل کاربرد الگوریتم‌ها به منظور "بهینه سازی"، در مقالات انتخاب شده

ردیف	منبع / تاریخ	الگوریتم	متغیر وابسته	نقاط ضعف (و راه حل‌ها)	نقاط قوت
۱	(Nasruddin et al. 2019)	ترکیبی از (ANN) و الگوریتم ژنتیک چند هدفه (MOGA)	به حداقل رساندن مصرف انرژی سالانه و به حداکثر رساندن آسایش حرارتی در یک دانشگاه با توجه به مقدار PPD	روند آموزش با بهینه سازی وزن و ضرایب بایاس ۱ برای به حداقل رساندن خطای موجود بین هدف و بازده ANN انجام شده است.	ANN طراحی شده، در مرحله آموزش پیش بینی دقیقی را نشان می‌دهد.
۲	(D'Amico et al. 2019)	ANN	پیشنهاد کاربرد شبکه عصبی مصنوعی، با هدف حل همزمان تعادل انرژی و محیط زیست ساختمانها	میانگین خطای مطلق و ضریب تصمیم ۲ به ترتیب کمتر از ۵٪ و نزدیک به ۱ بوده است.	پیاده سازی الگوریتم ANN در یک نرم افزار امکان ایجاد یک ابزار پشتیبانی مناسب برای تصمیم گیری را فراهم می‌کند. نتایج عالی تأیید کرده است که این روش را می‌توان در هر زمینه و شرایطی گسترش داد.

1. bias coefficients
2. determination coefficient

جدول ۳. تجزیه و تحلیل کاربرد الگوریتم‌ها به منظور "پیشنهاد یک روش جدید"، در مقالات انتخاب شده

شماره	منبع / تاریخ	الگوریتم	متغیر وابسته	نقاط ضعف (و راه حل‌ها)	نقاط قوت
۱	(Sharif and Hammad 2019)	ANN (از الگوریتم‌های پیشنهادی ANN می‌توان برای پیش بینی TEC، LCC و LCA به عنوان ابزاری برای شبیه سازی ساختمان استفاده کرد؛ همچنین زمان و انرژی لازم برای محاسبات کاهش می‌یابد.)	ایجاد پیوند بین SBMO و ANN ایجاد یک ANN قوی از مدل SBMO برای کشف داده‌های گسترده و پیچیده و پیشنهاد یک ANN دقیق برای پیش بینی مصرف انرژی با استفاده از داده‌های مدل SBMO.	ادغام کامل بین ANN و SBMO هنوز هم یک مشکل حل نشده در این تحقیق است. بخواه خصوص در مورد بازسازی ساختمان.	با توجه به نتایج، مدل‌های ساخته شده با شبکه‌های عصبی در مقایسه با مدل انرژی ساختمان (BEM) در مدت زمان کوتاهی به نتایج قابل قبولی می‌رسند.
۲	(Ilbeigi, Ghomeishi, and Dehghanbanadaki 2020)	شبکه عصبی با استفاده از مدل MLP بهینه سازی انرژی توسط پلاگین Galapagos بر اساس الگوریتم ژنتیک انجام شده است.	پیشنهاد یک روش قابل اعتماد برای بهینه سازی مصرف انرژی ساختمان‌ها (مصرف انرژی به عنوان تابع هدف انتخاب شده است)	ممکن است پارامترهای ورودی بیشتری برای ارزیابی ساختمانهای پیچیده تر استفاده شود. مانند HL, CL, آسایش حرارتی و اثرات زیست محیطی. با در نظر گرفتن سایر پارامترها، مصرف انرژی تعدیل خواهد شد. (در مطالعات آینده)	الگوریتم Garson برای مدل ANN، دقت بالایی را نشان می‌دهد. برای بازسازی ساختمان: ۹۹,۹٪.
۳	(Xu et al. 2019)	ادغام تحلیل شبکه اجتماعی (SNA) با تکنیک شبکه عصبی مصنوعی (ANN)	پیشنهاد یک روش جدید برای پیش بینی مصرف انرژی چند ساختمان (multi-building)	پیشنهادی-SNA-ANN برای پیش بینی استفاده از انرژی یک ساختمان منفرد در مقیاس شهر مورد تأیید قرار نگرفته است.	دقت در نتایج ۹۰,۲۸٪ برای پیش بینی مصرف انرژی در همه گروه‌های ساختمانی با روش SNA-ANN بدست آمده است.
۴	(Benedetti et al. 2016)	(ANNs)	ارائه یک روش کاملاً جدید برای کنترل مصرف انرژی، پیشنهاد یک روش مبتنی بر ANN و با هدف ایجاد یک سیستم کنترل خودکار برای مصرف انرژی	در صورت افت دائمی دقت، دو روش مختلف ایجاد می‌شود تا شبکه به طور خودکار مجدداً آموزش یابد.	روش پیشنهادی این امکان را دارد تا با انتخاب مناسب‌ترین ساختار ANN، یک مدل دقیق ایجاد شود و همچنین می‌توان مکانیزمی را که با استفاده از آن دقت مدل و علت کاهش دقت بررسی می‌شود را خودکار کرد.
۵	(Luo 2020)	هر پرو فایل هواشناسی، با متغیرهای زمانی متناظر و تقاضای سرمایش، برای آموزش زیر مدل ANN استفاده می‌شود.	پیشنهاد یک شبکه عصبی مصنوعی تطبیقی خوشه‌ای پیشرفته-C) ANN برای پیش‌بینی تقاضای سرمایش ساختمان در ۲۴ ساعت و در مناطق نیمه گرمسیری.	در مقایسه با مدل ANN معمولی با ساختار ثابت، خطای آموزش و آزمایش مدل پیشنهادی برای پیش‌بینی ۳,۵۹٪ و ۴,۷۱٪ بود که ۴,۲٪ و ۳,۱٪ بهبود داشته است.	-هر مدل فرعی ANN با ویژگی‌های پایگاه داده متغیرهای ورودی سازگار است. -عملکرد پیش بینی مدل پیشنهادی انطباقی شبکه خوشه‌ای تقویت شده ۱ بهبود یافته است.
۶	(Yang et al. 2020)	شبکه ANN با یک ساختار غیرخطی و برونزای اتورگرسیون. (سیستم پیشنهادی می‌تواند با استفاده از	پیشنهاد یک مدل (سیستم) کنترل پیش بینی به همراه مدل‌های ساختمانی مبتنی بر یادگیری ماشین با کاربرد	رویکرد مدل سازی مبتنی بر یادگیری ماشین می‌تواند به دلیل کمبود داده‌های لازم برای آموزش	ویژگی سازگاری مدل می‌تواند دقت پیش بینی مدل دینامیک ساختمان که مبتنی بر یادگیری ماشین است را تا حد زیادی بهبود

شماره	منبع / تاریخ	الگوریتم	متغیر وابسته	نقاط ضعف (و راه حل‌ها)	نقاط قوت
		داده‌های عملیات آنلاین ساخت و ساز از طریق ANN پویا با ساختار برونزای اتورگرسیون غیرخطی، مدل ساختمان را مرتباً به روز کند.	کنترل و اتوماسیون ساختمان	مدل در صورت توسعه مدل کنترل پیش بینی قبل از بهره برداری از ساختمان، به چالش کشیده شود.	بخشد و مزایایی را در عملکرد سیستم کنترل پیش بینی مدل ایجاد کند. دقت پیش بینی با افزایش تعداد داده‌های عملیات ساختمانی در طول زمان بهبود می‌یابد
۷	(Deb, Lee, and Santamouris 2018)	توسعه دو مدل با استفاده از MLR و ANN	پیشنهاد مدل‌های پیش بینی مرتبط با صرفه جویی در مصرف انرژی در ساختمان‌های اداری برای تهیه مطبوع؛ و روشی برای انتخاب مناسب‌ترین متغیرهای ورودی.	ANN محدودیت زیاد و سختگیرانه‌ای را روی مجموعه داده‌های آموزشی دارد. این امر منجر به بروز مشکلاتی از جمله بیش برآزش می‌شود که قابلیت پیش بینی دقیق را کاهش می‌دهد.	مدل ANN دقیق تر از مدل رگرسیون و با میانگین درصد مطلق خطا ۱ 14.8 (MAPE)٪ پیش بینی کرده است.
۸	(Jung, Kim, and Heo 2015)	Least-squares support vector machine (LSSVM) Direct search optimization (DSO) Real-coded genetic algorithm (RCGA)	طراحی یک ماشین بردار پشتیبان حداقل مربعات ۲ (LSSVM) برای پیش بینی مصرف انرژی روزانه ساختمان با استفاده از ترکیب الگوریتم بهینه سازی جستجوی مستقیم ۳ (DSO) و الگوریتم ژنتیک با کد واقعی ۴ (RCGA)، به نام DSORCGA.	برای جلوگیری از بیش برآزش یا کم برآزش که در مدل LSSVM موجود عمدتاً به دلیل تعیین نادرست پارامترها ایجاد شد، از DSORCGA برای انتخاب پارامترهای مناسب برای پیش بینی مصرف انرژی روزانه ساختمان استفاده شده است.	DSORCGA پیشنهادی از نظر اپراتور تکثیر و اپراتور همگرایی ۵ با RCGA معمولی متفاوت است و برای بهینه سازی پارامترهای آزاد از LSSVM با توجه به سرعت بیشتر در محاسبات و دقت پیش بینی بالاتر استفاده می‌شود.
۹	(Le, Bourdais, and Guéguen 2014)	SVM	ارائه روش ساخت یک کنترل کننده بسیار ساده با یادگیری رفتارهای کنترل کننده بهینه، با استفاده از SVM برای جلوگیری از ناراحتی حرارتی در ساختمان، که ممکن است در اواسط فصول معتدل و تابستان رخ دهد.	به منظور تولید داده‌ها برای یادگیری ماشین، موقعیت‌های مختلف ورودی در هر ۵ دقیقه و در طول شبیه سازی ثبت شده است. ورودی‌ها عبارتند از: دمای داخل خانه، بهره‌برداری از نور خورشید، دمای خارج و زمان.	روش SVM برای قوانین یادگیری ماشین از یک کنترلر بهینه، به ویژه برای کنترل موارد غیرخطی موثر است.


- 1 . mean absolute percentage error (MAPE)
- 2 . least-squares support vector machine (LSSVM)
- 3 . direct search optimization (DSO)
- 4 . real-coded genetic algorithm (RCGA)
- 5 . reproduction operator and the crossover operator

جدول ۴. تجزیه و تحلیل کاربرد الگوریتم‌ها به منظور "ارزیابی"، در مقالات انتخاب شده


ردیف	منبع / تاریخ	الگوریتم	متغیر وابسته	نقاط ضعف (و راه‌حل‌ها)	نقاط قوت
۱	(Wang, Lu, and Li 2019)	SVR, BPNN, RF, GBDT, and XGBoost با استفاده از موارد زیر: extreme gradient boosting (XGBoost), RF, ANN, gradient boosting decision tree (GBDT), and SVR	بررسی جامع بین عملکرد مدل‌های پیش‌بینی کننده معمول مورد استفاده بر اساس معیارهای عملکرد چندگانه (دقت) تفسیرپذیری، استحکام و کارایی)	برای دستیابی به دقت در یک سطح، ANN و SVR به الگوریتم‌های کمکی نیاز دارند، اما مدل‌های دیگر می‌توانند بدون نیاز به تنظیمات به دقت کافی دست یابند.	RF دقت متوسط را نشان می‌دهد اما ANN دارای خصوصیات مخالف است. - بالاترین مقاومت متعلق به RF است، اما XGBoost و ANN دارای خصوصیات مخالف هستند. - RF، GBDT و XGBoost کاملاً قابل تفسیر هستند. - XGBoost بهره‌وری مطلوب و بهینه را نشان می‌دهد.
۲	(Liu et al. 2019)	SVM-ANN	مقایسه ANN و SVM، به عنوان مدل‌های پرکاربرد و جهانی، از نظر پیچیدگی، فرآیندهای پیش‌بینی، دقت نتایج، مقادیر داده‌های تاریخی مورد نیاز، تعداد ورودی‌ها و غیره مقایسه شدند.	هر دو دارای نقاط قوت و کاستی‌هایی هستند. بنابراین، برای موارد مختلف، مدل‌هایی مناسب‌اند که با توجه به نیازها، ویژگی‌ها و فرایندهای آموزشی مربوطه انتخاب شوند.	از طریق مقایسه بین روش‌های یادگیری ماشین (ANN) و (SVM) به صورت واحد و ترکیبی، می‌توان دریافت که ویژگی‌های مختلفی هستند که در شرایط مختلف قابل اجرا می‌باشند.
۳	(Hošovský et al. 2021)	یک مدل جدید پیش‌بینی تحت عنوان شبکه عصبی موجک رگرسیون بهینه شده با الگوریتم ژنتیک genetic-algorithm-optimized regression wavelet neural network (GA-optimized regWANN)	پیش‌بینی مصرف روزانه گاز در طول یک هفته در سه نوع ساختمان، که دارای پروفیل‌های مختلف مصرف گاز در طی یک دوره پنج ساله هستند	مدل‌های متداول رگرسیون با خطاهای میانگین متحرک خود رگرسیون ^۱ (ARMA) (regARMA) هنگامی که پیش‌بینی‌های دما نادرست بوده‌اند، عملکرد ضعیفی را ارائه داده‌اند.	استفاده از روش GW بهینه شده regWANN برای پیش‌بینی مصرف روزانه گاز می‌تواند دقت پیش‌بینی را بهبود بخشد، حتی در شرایطی که خطاهای پیش‌بینی دما قابل توجه‌تر هستند.
۴	(Chou and Bui 2014)	- Support vector regression (SVR), - Artificial neural network (ANN), - Classification and regression tree, - Chi squared automatic interaction detector, - General linear regression, - Ensemble inference model.	برآورد عملکرد انرژی (بار خنک کننده و گرمایش) ساختمانها و مقایسه نتایج بدست آمده از الگوریتم‌های مختلف.	محدودیت این کار این است که از تنظیمات پیش‌فرض در مدل‌های تک و گروهی استفاده شده است. هوش مصنوعی فردی می‌تواند با الگوریتم‌های محاسباتی دیگر مانند الگوریتم ژنتیک، منطق فازی، بهینه‌سازی ازدحام ذرات و الگوریتم کلنی کرم شب تاب ادغام شود تا عملکرد مدل‌های AI منفرد را در بسیاری از زمینه‌های مهندسی عمران افزایش دهد.	این کار همچنین تأیید کرد که مدل گروه + SVR (ANN و SVR) به ترتیب عملکرد بهتری را در پیش‌بینی CL و HL داشته‌اند. علاوه بر این، آنها مقدار کار و انرژی مورد نیاز برای توسعه الگوریتم‌های پیچیده محاسبات را کاهش داده‌اند.
۵	(Ahmad, Mourshed, and Rezgui 2017)	RF و ANN (مقایسه بین آنها)	پیش‌بینی مصرف انرژی در هتلی در مادرید	طبق نتایج، به طور کلی، ANN عملکرد بهتری نسبت به RF با خطای میانگین مربع (RMSE) به ترتیب ۴٫۹۷ و ۶٫۱۰ داشته است.	- به طور کلی، مدل ANN عملکرد بهتری نسبت به مدل RF داشته است. - مدل RF می‌تواند به عنوان ابزاری برای انتخاب متغیر مورد استفاده قرار گیرد.

^۱ autoregressive moving averages (ARMA)

مطابق جدول ۴، که در آن فقط مقالاتی بررسی شده‌اند که هدف اصلی آنها "ارزیابی" بوده است؛ نتیجه‌گیری می‌شود که در بیشتر مقالات، الگوریتم‌های ANN و SVM به طور همزمان استفاده شده‌اند و هدف اصلی در آنها مقایسه بوده است؛ مقایسه عملکرد و نتایج الگوریتم‌ها با یکدیگر یا مقایسه پروفایل‌های مختلف در مبحث داده‌ها. نکته کلیدی در مقایسه منصفانه الگوریتم‌های یادگیری ماشین اطمینان از ارزیابی هر الگوریتم به همان روش و در داده‌های یکسان است. با بکارگیری هر الگوریتم برای ارزیابی در یک آزمون، می‌توان به این مهم دست پیدا کرد. (Brownlee 2016)



نمودار ۱. درصد استفاده از هر الگوریتم در سالهای مختلف



نمودار ۲. فراوانی استفاده از هر الگوریتم در مقالات بررسی شده

۲. بیشترین فراوانی را در بین الگوریتم‌های به کار برده شده در مقالات دارد. همانطور که ذکر شد، هدف اصلی این مطالعه شناسایی پرکاربردترین الگوریتم‌ها برای تحقیقات مربوط به پیش بینی و بهینه سازی انرژی مصرفی در ساختمان بوده است. ANN با کاربرد گسترده خود در این زمینه رتبه اول را دارد. به این ترتیب، در ادامه ویژگی‌های مختلف این الگوریتم با استفاده از مقالات بررسی شده و نوع اهداف هر مطالعه شرح داده شده است.

تکنیک‌های شبکه عصبی مصنوعی (ANN) از قابلیت‌های بسیاری در مدل سازی الگوهای پیچیده و غیرخطی برخوردار هستند. روند آموزش الگوریتم با تعداد مشخصی از سلول‌های عصبی و لایه‌های مغزی شبیه طبیعت مغز انسان است. معماری استاندارد ANN از ورودی‌ها، خروجی‌ها و لایه‌های پنهان تشکیل شده است. لایه ورودی از کلیه مقادیر ورودی تشکیل شده و لایه خروجی نتیجه نهایی را تولید می‌کند. وجود لایه (های) پنهان اساساً تضمین می‌کند که به دلیل وجود رابطه بین نورون‌های ورودی و خروجی مدل‌های شبکه عصبی دارای روابط غیر خطی هستند. (Lippmann 1994)

بنابراین، الگوریتم ANN دارای ساختاری لایه‌ای است و از طرف دیگر، متغیرهای بسیاری برای پیش بینی و بهینه سازی مصرف انرژی ساختمان با استفاده از هوش مصنوعی در نظر گرفته می‌شوند. به همین راحتی، هر یک از آنها را می‌توان در جایگاه لایه‌های ورودی مختلف الگوریتم قرار داد. علاوه بر این، ANN دارای سرعت و دقت بالایی است. بنابراین می‌تواند به راحتی برای پیش بینی به طور گسترده مورد استفاده قرار گیرد و قابل اعتماد باشد.

ANN یک مدل محاسباتی است که سعی در شبیه سازی ساختار یا جنبه‌های عملکردی شبکه‌های عصبی بیولوژیکی دارد. (Banihashemi, Ding, and Wang 2017) مهم نیست که از چه نوع معماری شبکه‌ای استفاده شده است، یک مدل ANN باید فرایند آموزش (یادگیری) را تجربه کند تا قبل از کاربردهای واقعی تمام وزن و ارتباطات مورد نیاز را مشخص کند. در روند آموزش از سوابق موجود داده‌های تاریخی استفاده خواهد شد، که به عنوان معیارهایی برای نتیجه‌گیری مناسب مدل ANN در رابطه با ورودی‌های داده شده استفاده می‌شود. بنابراین، شبکه‌های عصبی قادر به یادگیری رابطه بین سیگنال‌های ورودی و گرفتن اطلاعات مهم از طریق یک فرایند آموزش مبتنی بر سوابق داده‌های تاریخی هستند. همچنین، این الگوریتم دارای یک

با توجه به مقالات بررسی شده در جداول بالا، ۸۵٪ از مقالات با اهداف مربوط به پیش بینی و بهینه سازی مصرف انرژی در ساختمان‌ها، فقط از الگوریتم ANN استفاده کرده و یا آن را با الگوریتم یا روش دیگری برای اهداف خود ترکیب کرده‌اند. پس از ANN، این الگوریتم‌ها بیشترین فراوانی را در مقالات منتخب داشتند: ماشین بردار پشتیبان (SVM)، جنگل تصادفی (RF)، الگوریتم ژنتیک (GA) و رگرسیون خطی (LR). از نمودار ۱، دو نکته را می‌توان نتیجه گیری کرد:


۱. الگوریتم ANN بیشترین فراوانی را داشته است.

۲. با توجه به اهمیت بهره وری انرژی ساختمان در سالهای اخیر، بیشتر مقالات بررسی شده مربوط به سالهای ۲۰۱۹ و ۲۰۲۰ هستند.

از نمودار ۲، دو نکته دریافت می‌شود:

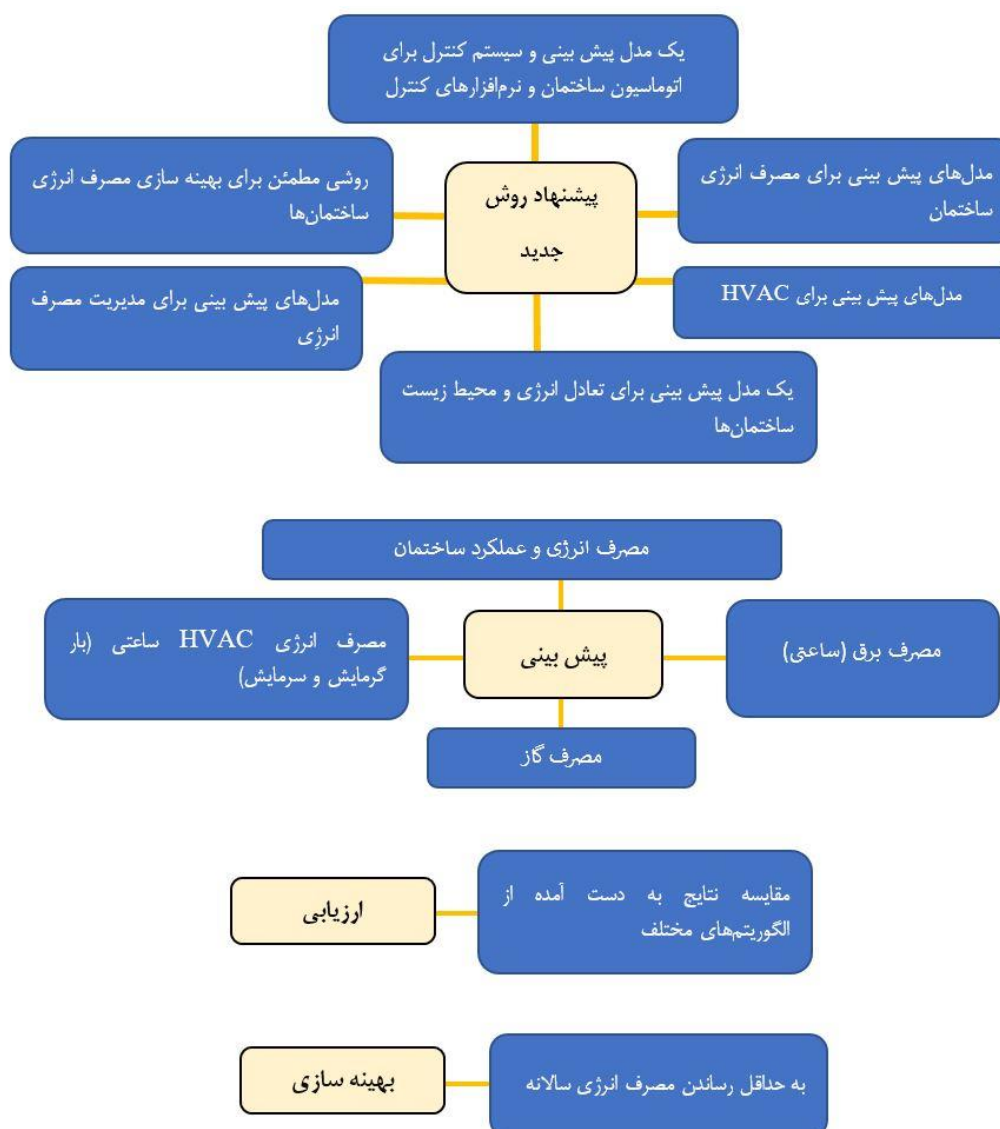
۱. پنج الگوریتم نشان داده شده در نمودار پر کاربردترین الگوریتم‌ها در مقالات منتخب بوده‌اند.

سری مزایای دیگر است، مانند تحمل خطا، مصونیت از اختلال و قدرت. با توجه به این ویژگی‌های مطلوب، شبکه‌های ANN تاکنون در حل مشکلات غیرخطی به موفقیت برتر دست یافته‌اند. (Kalogirou 2000)



با توجه به اینکه الگوریتم ANN پرکاربردترین الگوریتم در مطالعات مروری است و اهداف مختلفی برای استفاده از آن در نظر گرفته شده است، دیاگرام ۱ طبقه بندی این رویکردها را نشان می‌دهد: دیاگرام ۲ در ادامه بیشتر توضیح داده شده است:

دیاگرام ۱. کاربرد متفاوت ANN در مطالعات مروری



دیاگرام ۲. اهداف مختلف استفاده از الگوریتم ANN در مطالعات مروری

مطابق دیاگرام فوق، الگوریتم ANN می‌تواند برای تمام اهداف مربوط به پیش بینی و بهینه سازی مصرف انرژی با استفاده از هوش مصنوعی مورد استفاده قرار گیرد. در ادامه، اشکالات یا نکات مربوط به الگوریتم ANN که در مقالات ذکر شده است را بررسی خواهیم کرد.

معایب استفاده از شبکه‌های عصبی مصنوعی به طور کلی عبارتند از:

۱. جعبه سیاه: مسلماً مشهورترین نقطه ضعف شبکه عصبی ماهیت "جعبه سیاه" است. به عبارت دیگر، شما نمی‌دانید که ANN چگونه و چرا خروجی خاصی را ارائه می‌دهد.
۲. مدت زمان توسعه: اگرچه کتابخانه‌هایی مانند "Keras" وجود دارد که توسعه شبکه‌های عصبی را به راحتی ساده سازی می‌کند، اما گاهی اوقات به کنترل بیشتری بر روی جزئیات الگوریتم نیاز است، مانند زمانی که می‌خواهید یک مسئله سخت و پیچیده را به کمک یادگیری ماشین حل کنید که هیچ کس قبلاً آنرا انجام نداده است.
۳. مقدار داده: شبکه‌های عصبی معمولاً به داده‌های بسیار بیشتری نسبت به الگوریتم‌های یادگیری ماشین سنتی و معمول نیاز دارند، حداقل هزاران داده؛ در غیر این صورت میلیون‌ها نمونه برچسب خورده نیاز است. حل این مسئله آسان نیست و بسیاری از مشکلات یادگیری ماشین در صورت استفاده از الگوریتم‌های دیگر با داده کمتر می‌تواند به راحتی حل شود.
۴. محاسبات سنگین: به طور کلی، شبکه‌های عصبی از نظر محاسباتی سنگین‌تر از الگوریتم‌های سنتی و معمول هستند. الگوریتم‌های یادگیری عمیق^۱ می‌توانند به طور موفقیت آمیز شبکه‌های عصبی عمیق را آموزش دهند و این کار پیچیده را تحقق بخشند، این آموزش به طور کامل و به صورت پیش نویس^۲ ممکن است چندین هفته طول بکشد. از طرفی دیگر، اکثر الگوریتم‌های یادگیری ماشین (سنتی و معمول) زمان بسیار کمتری را برای این کار می‌طلبند و این زمان ممکن است از چند دقیقه تا چند ساعت یا چند روز متغیر باشد. ("4 Disadvantages Of Neural Networks | Built In" n.d.)

۵- نتیجه‌گیری

هدف از این مطالعه مروری معرفی متداول‌ترین الگوریتم‌های یادگیری ماشین تحت نظارت برای پیش بینی عملکرد انرژی ساختمان و توصیف مزایا و محدودیت‌های آنها بوده است. در سال‌های اخیر، در بسیاری از مطالعات از الگوریتم‌های یادگیری ماشین برای پیش بینی عملکرد انرژی ساختمان‌ها استفاده شده است، به این دلیل که سریعتر از روش‌های معمول است و از دقت بالاتری نیز برخوردار است. در این مطالعه، بسیاری از مقالات منتشر شده در ۸ سال گذشته که هدف آنها بهینه سازی یا پیش بینی مصرف انرژی ساختمان‌ها با استفاده از هوش مصنوعی است، بررسی شده‌اند. در این میان، الگوریتم‌هایی که بیشتر از بقیه به منظور بهینه سازی مصرف انرژی و پیش بینی عملکرد انرژی ساختمان‌ها مورد استفاده قرار گرفته‌اند به ترتیب ANN، SVM، RF، GA و LR بوده‌اند. هر الگوریتم ویژگی‌های خاص خود را دارد و برای اهداف مختلفی مورد استفاده قرار می‌گیرد و هیچ تمایزی برای بهتر یا بدتر بودن آن نسبت به بقیه وجود ندارد؛ مهم این است که الگوریتم به درستی و متناسب با هدف انتخاب شود. با توجه به اینکه ANN پرکاربردترین الگوریتم در این زمینه بوده است، ویژگی‌های آن بیشتر مورد بررسی قرار گرفته و نتیجه گیری این است که به دلیل لایه لایه بودن شبکه ANN، این الگوریتم می‌تواند گزینه مناسبی برای پیش بینی یا بهینه سازی مصرف انرژی باشد؛ زیرا معمولاً چندین متغیر برای ارزیابی عملکرد انرژی ساختمان در نظر گرفته می‌شود و این متغیرها را می‌توان به راحتی در لایه‌های مختلف ورودی الگوریتم قرار داد. علاوه بر این، ANN نیز مانند هر الگوریتم دیگری دارای اشکالاتی است و از راه حل‌های مختلفی برای افزایش دقت و سرعت آن در پژوهش‌های انجام شده تا به اکنون، استفاده شده است. یکی از این راه حل‌ها ادغام الگوریتم اصلی با الگوریتم‌ها یا روش‌های دیگر برای بهبود عملکرد آن است. مشکل دیگری که ممکن است ایجاد شود ناقص بودن داده‌های موجود است و یا اینکه الگوریتم توانایی به روز کردن داده‌ها را نداشته باشد. هر الگوریتم یادگیری ماشین نیازهای شرطی خاص خود را دارد و انتخاب هر یک از آنها میبایست با توجه به نیاز و داده‌های موجود انجام شود. (Luo 2020) نتیجه‌گیری این است که اگر الگوریتم‌های یادگیری ماشین به درستی انتخاب شوند، پیش بینی‌های دقیق‌تری را ارائه می‌دهند و در نهایت با اطمینان می‌توان از نتایج برای بهینه سازی مصرف انرژی استفاده کرد.

پی نوشت: جدول مخفف‌ها

ANN	Artificial Neural Network شبکه عصبی مصنوعی	RF	Random Forest جنگل تصادفی
RMSE	Root Mean Squared Error جذر میانگین مجذور خطا	SVM	Support Vector Machine ماشین بردار پشتیبان
DNN	Deep Neural Network شبکه عصبی عمیق	SVR	Support Vector Regression رگرسیون بردار پشتیبان
DT	Decision Tree درخت تصمیم گیری	SBMO	Simulation-Based Multi-Objective Optimization بهینه سازی چند هدفه مبتنی بر شبیه سازی
MLP	Multi-Layer Perceptron پرسترون چند لایه	GA	Genetic Algorithm الگوریتم ژنتیک
LR	Linear Regression رگرسیون خطی	MOGA	Multi-Objective Genetic Algorithm الگوریتم ژنتیک چند منظوره
CL	Cooling Load بار سرمایشی	HL	Heating Load بار گرمایشی
HVAC	Heating, Ventilation and Air-Conditioning گرمایش، تهویه و تهویه مطبوع	EFA	electromagnetism-based firefly algorithm الگوریتم کرم شب تاب مبتنی بر مغناطیس
TCV	Thermal Comfort Votes آراء مربوط به آسایش حرارتی	LCC	Life Cycle Cost هزینه چرخه حیات
TEC	Total Energy Consumption کل مصرف انرژی	LCA	Life Cycle Assessment ارزیابی چرخه حیات
TSV	Thermal Sensation Votes آراء احساس راحتی	PPD	percentage of people dissatisfied درصد مردم ناراضی
MLP	multi-layer perceptron پرسترون چند لایه	SNA	Social Network Analysis تحلیل شبکه اجتماعی
MLR	Multiple Linear Regression رگرسیون خطی چند گانه	MAPE	Mean Absolute Percentage Error جذر میانگین مجذور خطا
CBECS	Commercial Building Energy Consumption Survey نظرسنجی مصرف انرژی ساختمان تجاری	EUI	Energy Use Intensity شدت مصرف انرژی
Boosted Tree	درخت تقویت شده	ASHRAE	American Society of Heating, Refrigerating and Air Conditioning Engineers انجمن مهندسان سیستم‌های گرمایشی، برودتی و تهویه مطبوع آمریکا
TLBO	teaching learning-based optimization بهینه سازی مبتنی بر آموزش و یادگیری		
GP	Genetic Programming برنامه نویسی ژنتیکی		

قدردانی

بدین‌وسیله از حمایت خانم دکتر مه‌اسادات ترابی در ایده‌پردازی این تحقیق کمال تشکر و قدردانی را دارم.

منابع

۱. ترابی، مهسا سادات. ۱۳۹۹. "بهره‌وری انرژی ساختمان با استفاده از عامل‌های یادگیرنده رفتار کاربر نمونه مطالعاتی: منتخب ساختمان‌های مسکونی شهر تهران." گروه معماری. دانشگاه تربیت مدرس.
2. "4 Disadvantages Of Neural Networks | Built In." n.d. Accessed December 20, 2020. <https://builtin.com/data-science/disadvantages-neural-networks>.
3. Ahmad, Muhammad Waseem, Monjur Mourshed, and Yacine Rezgui. 2017. "Trees vs Neurons: Comparison between Random Forest and ANN for High-Resolution Prediction of Building Energy Consumption." *Energy and Buildings* 147: 77–89. <https://doi.org/10.1016/j.enbuild.2017.04.038>.
4. AlTabbaa, Omar, and Samuel Ankrah. 2016. "University of Huddersfield Repository." *Technological Forecasting & Social Change* 104 (December 2017): 1–15.

5. Banihashemi, Saeed, Grace Ding, and Jack Wang. 2017. "Developing a Hybrid Model of Prediction and Classification Algorithms for Building Energy Consumption." *Energy Procedia* 110 (December 2016): 371–76. <https://doi.org/10.1016/j.egypro.2017.03.155>.
6. Barnaby, C., and J. Spitler. 2005. "Development of the Residential Load Factor Method for Heating and Cooling Load Calculations." *Undefined*.
7. Benedetti, Miriam, Vittorio Cesarotti, Vito Introna, and Jacopo Serranti. 2016. "Energy Consumption Control Automation Using Artificial Neural Networks and Adaptive Algorithms: Proposal of a New Methodology and Case Study." *Applied Energy* 165: 60–71. <https://doi.org/10.1016/j.apenergy.2015.12.066>.
8. Bourdeau, Mathieu, Xiao qiang Zhai, Elyes Nefzaoui, Xiaofeng Guo, and Patrice Chatellier. 2019. "Modeling and Forecasting Building Energy Consumption: A Review of Data-Driven Techniques." *Sustainable Cities and Society* 48. <https://doi.org/10.1016/j.scs.2019.101533>.
9. Breiman, Leo. 2001. "Random Forests." *Machine Learning* 45 (1): 5–32. <https://doi.org/10.1023/A:1010933404324>.
10. Brownlee, Jason. 2016. "How To Compare Machine Learning Algorithms in Python with Scikit-Learn." 2016. <https://machinelearningmastery.com/compare-machine-learning-algorithms-python-scikit-learn/>.
11. Bui, Dac Khuong, Tuan Ngoc Nguyen, Tuan Duc Ngo, and H. Nguyen-Xuan. 2020. "An Artificial Neural Network (ANN) Expert System Enhanced with the Electromagnetism-Based Firefly Algorithm (EFA) for Predicting the Energy Consumption in Buildings." *Energy* 190. <https://doi.org/10.1016/j.energy.2019.116370>.
12. Cavaleiro, José, and Paulo Carreira. 2016. "A Multidimensional Data Model Design for Building Energy Management." *Advanced Engineering Informatics* 30 (4): 619–32. <https://doi.org/10.1016/j.aei.2016.08.001>.
13. Chai, Qian, Huiqin Wang, Yongchao Zhai, and Liu Yang. 2020. "Using Machine Learning Algorithms to Predict Occupants' Thermal Comfort in Naturally Ventilated Residential Buildings." *Energy and Buildings* 217: 109937. <https://doi.org/10.1016/j.enbuild.2020.109937>.
14. Chakraborty, Debaditya, Hazem Elzarka, and Raj Bhatnagar. 2016. "Generation of Accurate Weather Files Using a Hybrid Machine Learning Methodology for Design and Analysis of Sustainable and Resilient Buildings." *Sustainable Cities and Society* 24: 33–41. <https://doi.org/10.1016/j.scs.2016.04.009>.
15. Chou, Jui Sheng, and Dac Khuong Bui. 2014. "Modeling Heating and Cooling Loads by Artificial Intelligence for Energy-Efficient Building Design." *Energy and Buildings* 82 (2014): 437–46. <https://doi.org/10.1016/j.enbuild.2014.07.036>.
16. D'Amico, A., G. Ciulla, M. Traverso, V. Lo Brano, and E. Palumbo. 2019. "Artificial Neural Networks to Assess Energy and Environmental Performance of Buildings: An Italian Case Study." *Journal of Cleaner Production* 239: 117993. <https://doi.org/10.1016/j.jclepro.2019.117993>.
17. Deb, Chirag, Siew Eang Lee, and Mattheos Santamouris. 2018. "Using Artificial Neural Networks to Assess HVAC Related Energy Saving in Retrofitted Office Buildings." *Solar Energy* 163 (August 2017): 32–44. <https://doi.org/10.1016/j.solener.2018.01.075>.
18. Deng, Hengfang, David Fannon, and Matthew J. Eckelman. 2018. "Predictive Modeling for US Commercial Building Energy Use: A Comparison of Existing Statistical and Machine Learning Algorithms Using CBECS Microdata." *Energy and Buildings* 163: 34–43. <https://doi.org/10.1016/j.enbuild.2017.12.031>.
19. Drucker, H., C. Burges, L. Kaufman, Alex Smola, and V. Vapnik. 1996. "Support Vector Regression Machines." *Undefined*.
20. Hošovský, Alexander, Ján Pitel, Milan Adámek, Jana Mižáková, and Kamil Židek. 2021. "Comparative Study of Week-Ahead Forecasting of Daily Gas Consumption in Buildings Using Regression ARMA/SARMA and Genetic-Algorithm-Optimized Regression Wavelet Neural Network Models." *Journal of Building Engineering* 34 (October). <https://doi.org/10.1016/j.job.2020.101955>.
21. Hwang, Junhwa, Dongjun Suh, and Marc-Oliver Otto. 2020. "Forecasting Electricity Consumption in Commercial Buildings Using a Machine Learning Approach." *Energies* 13 (22): 5885. <https://doi.org/10.3390/en13225885>.
22. Ilbeigi, Marjan, Mohammad Ghomeshi, and Ali Dehghanbanadaki. 2020. "Prediction and Optimization of Energy Consumption in an Office Building Using Artificial Neural Network and a Genetic Algorithm." *Sustainable Cities and Society* 61: 102325. <https://doi.org/10.1016/j.scs.2020.102325>.

23. Jason Brownlee. 2016. "Supervised and Unsupervised Machine Learning Algorithms." 2016. <https://machinelearningmastery.com/supervised-and-unsupervised-machine-learning-algorithms/>.
24. Jung, Hyun Chul, Jin Sung Kim, and Hoon Heo. 2015. "Prediction of Building Energy Consumption Using an Improved Real Coded Genetic Algorithm Based Least Squares Support Vector Machine Approach." *Energy and Buildings* 90: 76–84. <https://doi.org/10.1016/j.enbuild.2014.12.029>.
25. Kallio, Johanna, Jaakko Tervonen, Pauli Räsänen, Riku Mäkynen, Jani Koivusaari, and Johannes Peltola. 2021. "Forecasting Office Indoor CO2 Concentration Using Machine Learning with a One-Year Dataset." *Building and Environment* 187 (October 2020). <https://doi.org/10.1016/j.buildenv.2020.107409>.
26. Kalogirou, Soteris A. 2000. "Artificial Neural Networks in Renewable Energy Systems Applications: A Review." *Renewable and Sustainable Energy Reviews*. Pergamon. [https://doi.org/10.1016/S1364-0321\(01\)00006-5](https://doi.org/10.1016/S1364-0321(01)00006-5).
27. Kim, Moon Keun, Yang Seon Kim, and Jelena Srebric. 2020. "Predictions of Electricity Consumption in a Campus Building Using Occupant Rates and Weather Elements with Sensitivity Analysis: Artificial Neural Network vs. Linear Regression." *Sustainable Cities and Society* 62: 102385. <https://doi.org/10.1016/j.scs.2020.102385>.
28. Le, Khang, Romain Bourdais, and Hervé Guéguen. 2014. "From Hybrid Model Predictive Control to Logical Control for Shading System: A Support Vector Machine Approach." *Energy and Buildings* 84: 352–59. <https://doi.org/10.1016/j.enbuild.2014.07.084>.
29. Li, Kangji, Xianming Xie, Wenping Xue, Xiaoli Dai, Xu Chen, and Xinyun Yang. 2018. "A Hybrid Teaching-Learning Artificial Neural Network for Building Electrical Energy Consumption Prediction." *Energy and Buildings* 174: 323–34. <https://doi.org/10.1016/j.enbuild.2018.06.017>.
30. Lippmann, Richard. 1994. "Book Review: 'Neural Networks, A Comprehensive Foundation', by Simon Haykin." *International Journal of Neural Systems* 05 (04): 363–64. <https://doi.org/10.1142/s0129065794000372>.
31. Liu, Zhijian, Di Wu, Yuanwei Liu, Zhonghe Han, Liyong Lun, Jun Gao, Guangya Jin, and Guoqing Cao. 2019. "Accuracy Analyses and Model Comparison of Machine Learning Adopted in Building Energy Consumption Prediction." *Energy Exploration and Exploitation* 37 (4): 1426–51. <https://doi.org/10.1177/0144598718822400>.
32. Lucasius, C. B., and G. Kateman. 1993. "Understanding and Using Genetic Algorithms Part 1. Concepts, Properties and Context." *Chemometrics and Intelligent Laboratory Systems*. Elsevier. [https://doi.org/10.1016/0169-7439\(93\)80079-W](https://doi.org/10.1016/0169-7439(93)80079-W).
33. Luo, X. J. 2020. "A Novel Clustering-Enhanced Adaptive Artificial Neural Network Model for Predicting Day-Ahead Building Cooling Demand." *Journal of Building Engineering* 32: 101504. <https://doi.org/10.1016/j.job.2020.101504>.
34. Luo, X. J., Lukumon O. Oyedele, Anuoluwapo O. Ajayi, Olugbenga O. Akinade, Hakeem A. Owolabi, and Ashraf Ahmed. 2020. "Feature Extraction and Genetic Algorithm Enhanced Adaptive Deep Neural Network for Energy Consumption Prediction in Buildings." *Renewable and Sustainable Energy Reviews* 131 (June): 109980. <https://doi.org/10.1016/j.rser.2020.109980>.
35. Luo, X.J., Lukumon O. Oyedele, Anuoluwapo O. Ajayi, Olugbenga O. Akinade, Juan Manuel Davila Delgado, Hakeem A. Owolabi, and Ashraf Ahmed. 2020. "Genetic Algorithm-Determined Deep Feedforward Neural Network Architecture for Predicting Electricity Consumption in Real Buildings." *Energy and AI* 2 (7): 100015. <https://doi.org/10.1016/j.egyai.2020.100015>.
36. Nasruddin, Sholahudin, Pujo Satrio, Teuku Meurah Indra Mahlia, Niccolo Giannetti, and Kiyoshi Saito. 2019. "Optimization of HVAC System Energy Consumption in a Building Using Artificial Neural Network and Multi-Objective Genetic Algorithm." *Sustainable Energy Technologies and Assessments* 35 (October 2018): 48–57. <https://doi.org/10.1016/j.seta.2019.06.002>.
37. Seyedzadeh, Saleh, Farzad Pour Rahimian, Ivan Glesk, and Marc Roper. 2018. "Machine Learning for Estimation of Building Energy Consumption and Performance: A Review." *Visualization in Engineering* 6 (1). <https://doi.org/10.1186/s40327-018-0064-7>.
38. Sharif, Seyed Amirhosain, and Amin Hammad. 2019. "Developing Surrogate ANN for Selecting Near-Optimal Building Energy Renovation Methods Considering Energy Consumption, LCC and LCA." *Journal of Building Engineering* 25: 100790. <https://doi.org/10.1016/j.job.2019.100790>.

39. "SVM Vs Neural Network | Baeldung on Computer Science." n.d. Accessed April 9, 2021. <https://www.baeldung.com/cs/svm-vs-neural-network>.
40. Villarrubia, Gabriel, Juan F. De Paz, Pablo Chamoso, and Fernando De la Prieta. 2018. "Artificial Neural Networks Used in Optimization Problems." *Neurocomputing* 272: 10–16. <https://doi.org/10.1016/j.neucom.2017.04.075>.
41. Walker, Shalika, Waqas Khan, Katarina Katic, Wim Maassen, and Wim Zeiler. 2020. "Accuracy of Different Machine Learning Algorithms and Added-Value of Predicting Aggregated-Level Energy Performance of Commercial Buildings." *Energy and Buildings* 209: 109705. <https://doi.org/10.1016/j.enbuild.2019.109705>.
42. Wang, Ran, Shilei Lu, and Qiaoping Li. 2019. "Multi-Criteria Comprehensive Study on Predictive Algorithm of Hourly Heating Energy Consumption for Residential Buildings." *Sustainable Cities and Society* 49 (April): 101623. <https://doi.org/10.1016/j.scs.2019.101623>.
43. Weerts, Hilde J.P., Andreas C. Müller, and Joaquin Vanschoren. 2020. "Importance of Tuning Hyperparameters of Machine Learning Algorithms." *ArXiv*.
44. Wei, Yixuan, Xingxing Zhang, Yong Shi, Liang Xia, Song Pan, Jinshun Wu, Mengjie Han, and Xiaoyun Zhao. 2018. "A Review of Data-Driven Approaches for Prediction and Classification of Building Energy Consumption." *Renewable and Sustainable Energy Reviews* 82 (September): 1027–47. <https://doi.org/10.1016/j.rser.2017.09.108>.
45. Xu, Xiaodong, Wei Wang, Tianzhen Hong, and Jiayu Chen. 2019. "Incorporating Machine Learning with Building Network Analysis to Predict Multi-Building Energy Use." *Energy and Buildings* 186: 80–97. <https://doi.org/10.1016/j.enbuild.2019.01.002>.
46. Yang, Shiyu, Man Pun Wan, Wanyu Chen, Bing Feng Ng, and Swapnil Dubey. 2020. "Model Predictive Control with Adaptive Machine-Learning-Based Model for Building Energy Efficiency and Comfort Optimization." *Applied Energy* 271 (January): 115147. <https://doi.org/10.1016/j.apenergy.2020.115147>.
47. Zhao, Hai Xiang, and Frédéric Magoulès. 2012. "A Review on the Prediction of Building Energy Consumption." *Renewable and Sustainable Energy Reviews*. <https://doi.org/10.1016/j.rser.2012.02.049>.

An overview on the application of machine learning algorithms to predict the energy performance of a building

Nowadays, due to increasing importance of energy consumption, many methods have been applied aiming accurate. One of these methods is to use artificial intelligence. Many algorithms are used to do this; Which provide a more accurate result than other building energy simulation tools. This article, reviews some research that has been done in recent years, and related to this issue; To identify the most accurate and most widely used algorithms in this field; The algorithms have the lowest error rate, the highest speed and the most accurate calculations. When using different algorithms, the strengths and weaknesses of each are identified. Researchers have used various algorithms to predict the energy consumption of buildings. The purpose of this article is to better understand the features of different algorithms according to the type of their use; and introduce the best and most widely used machine learning algorithms in recent years. the most widely used methods in order to optimize energy consumption and predict the energy performance of buildings have been ANN, SVM, RF, GA and LR respectively. In this research, a layered framework has been used to select articles; In the first layer, articles that have been published in the recent years were considered; In the second layer, these articles had the keywords we wanted and were in line with our achievements; In the third layer, the subject of the articles was in line with our subject and machine learning algorithms were used to predict or optimize the energy consumption of building.

Keywords: Machine Learning Algorithms, Energy Prediction, Energy Performance, Building Energy Efficiency, Accuracy.