



Mid-Term Residential Load Forecasting Based on Feature Selection Using Neighborhood Component Analysis

Iman Bahadornejad¹, Majid Moazzami^{1,2}, Ghazanfar Shahgholian^{1,2}, Bahador Fani^{1,2}, Mahnaz Hashemi^{1,2}

¹Department of Electrical Engineering, Islamic Azad University of Najafabad, Najafabad, Iran

²Smart Microgrid Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran

Abstract:

Residential load forecasting plays an important role in management and planning of modern smart grids. Accurate residential load forecasting is needed in planning to keep demand and supply balanced. This paper presents a mid-term residential load forecasting method based on feature selection to solve the linear regression problem. In this way, for feature selection to perform the regression, the neighborhood component analysis method is used. For this purpose, an optimization problem is designed, and the problem is solved using the LBFGS algorithm. The AMPds2 dataset is used to implement the proposed method, and the results were compared with the results of the other six forecasting methods. Comparisons were made through mean squared error, root mean squared error, and mean absolute percentage error. The simulation results confirm the effectiveness of the proposed method for accurate residential load forecasting.

Keywords: Mid-Term Forecasting, Neighborhood Component Analysis, LBFGS Algorithm, Mean Squared Error, Mean Absolute Percentage Error.



مقاله پژوهشی

پیش‌بینی میان‌مدت بار مسکونی مبتنی بر انتخاب ویژگی به روش تحلیل اجزای مجاور

ایمان بهادرنژاد^۱، مجید معظمی^۲، غضنفر شاهقلیان^{۳*}، بهادر فانی^۴، مهناز هاشمی^۲

۱- دانشجوی دکتری، دانشکده مهندسی برق- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

ibahadornejad@gmail.com

۲- استادیار، دانشکده مهندسی برق- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

m_moazzami@pel.iaun.ac.ir, m.hashemi@pel.iaun.ac.ir

۳- دانشیار، دانشکده مهندسی برق- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

shahgholian@iaun.ac.ir, b.fani@pel.iaun.ac.ir

۴- مرکز تحقیقات ریزش‌بکه‌های هوشمند، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

چکیده: پیش‌بینی بار مسکونی نقش مهمی در مدیریت و برنامه‌ریزی در شبکه‌های هوشمند مدرن دارد. در برنامه‌ریزی برای متعادل نگه داشتن تقاضا و تولید توان، لازم است پیش‌بینی دقیقی از بار مناطق مسکونی انجام شود. در این مقاله، یک روش پیش‌بینی میان‌مدت بار مسکونی مبتنی بر انتخاب ویژگی برای حل مسئله رگرسیون خطی ارائه شده است؛ به این ترتیب که برای انتخاب ویژگی به منظور انجام رگرسیون، از روش تحلیل اجزای مجاور استفاده می‌شود. بنابراین، یک مسئله بهینه‌سازی طرح شده است؛ مسئله مذکور با استفاده از الگوریتم حافظه محدود BFGS (LBFGS) حل می‌شود. مجموعه داده‌های AMPds2 برای اجرای روش پیشنهادی استفاده شد و نتایج به دست آمده با نتایج شش روش پیش‌بینی دیگر مقایسه شدند. مقایسه از طریق شاخص‌های میانگین مربعات خطا، جذر میانگین مربعات خطا و میانگین مطلق درصد خطا انجام شد و نتایج شبیه‌سازی مؤثر بودن روش پیشنهادی را برای پیش‌بینی دقیق بار مسکونی تأیید کردند.

واژه‌های کلیدی: پیش‌بینی میان‌مدت، تحلیل اجزای مجاور، الگوریتم LBFGS، میانگین مربعات خطا، میانگین مطلق درصد

۱- مقدمه

مدیریت عملکرد سیستم‌های قدرت ضروری‌اند [۱]. با افزایش نفوذ توان تولیدشده از منابع تجدیدپذیری همچون باد و نور خورشید و تغییر الگوی مصرف و نوع بار در مناطق مسکونی، پیش‌بینی توان مورد نیاز این نوع مصرف‌کنندگان پیچیده‌تر و سخت‌تر شده است؛ برای مثال، استفاده از خودروهای الکتریکی و نیاز این نوع خودروها به شارژ شدن در منازل مسکونی، موجب افزایش مصرف توان و عدم قطعیت‌های موجود در سیستم‌های قدرت خواهد شد. پیش‌بینی دقیق بار در سطح مصرف‌کنندگان مناطق مسکونی موجب ساده‌تر شدن عملیات در سیستم‌های قدرت می‌شود. همچنین پیش‌بینی بار مسکونی مقدمه‌ای برای استفاده از منابع تجدیدپذیر در تأمین توان مورد نیاز منازل مسکونی است. همچنین از این طریق، چگونگی استفاده از فن‌آوری‌های جدید مانند اتصال خودروهای الکتریکی به

پیش‌بینی بار نقش مهمی در توسعه و مدرن‌سازی سیستم‌های قدرت دارد. پیش‌بینی بار از نظر مدت زمان پیش‌بینی، به دسته‌های کوتاه‌مدت، میان‌مدت و بلندمدت تقسیم می‌شود. پیش‌بینی بلندمدت بار برای برنامه‌ریزی ساختن تأسیسات تولید توان استفاده می‌شود؛ در حالی که پیش‌بینی‌های کوتاه‌مدت و میان‌مدت برای برنامه‌ریزی و

^۱ تاریخ ارسال مقاله: ۱۳۹۸/۱۰/۲۸

تاریخ پذیرش مقاله: ۱۳۹۹/۰۹/۰۱

نام نویسنده مسئول: غضنفر شاهقلیان

نشانی نویسنده مسئول: ایران، نجف‌آباد، دانشگاه آزاد اسلامی، واحد نجف‌آباد، دانشکده مهندسی برق

روش‌های یادگیری ماشین همچون شبکه عصبی چندلایه و رگرسیون ماشین بردار پشتیبان پیش‌بینی شده است. در مرجع [۶] از شبکه عصبی چندلایه پیش‌خور برای پیش‌بینی روز - پیش بار مسکونی در شهر آمستردام هلند استفاده شده است. روش‌های یادگیری عمیق در بسیاری از زمینه‌ها مانند شناسایی تصویر و صوت بررسی شده‌اند و نتایج خوبی ارائه داده‌اند. در مراجع [۳]، [۷] و [۸] از شبکه عصبی حافظه کوتاه‌مدت بلند^۱ (LSTM) برای انجام پیش‌بینی بار مسکونی مبتنی بر داده‌های اندازه‌گیری شده استفاده شده است. در این پژوهش‌ها مقایسه بسیار خوبی میان نتایج به‌دست‌آمده با استفاده از این نوع شبکه عصبی با سایر روش‌های یادگیری عمیق انجام شده است که نشان می‌دهد استفاده از شبکه عصبی کوتاه‌مدت بلند نتایج خوبی در پیش‌بینی بار مسکونی ارائه داده است.

در این مقاله، استفاده از روشی مبتنی بر انتخاب ویژگی برای حل مسئله رگرسیون خطی پیشنهاد می‌شود. این روش با نام تحلیل اجزای مجاور^۲ شناخته می‌شود و برای حل مسائل دسته‌بندی و رگرسیون در مباحث یادگیری ماشین استفاده شده است. در این روش از الگوریتم حافظه محدود BFGS^۳ LBGFS برای حل مسائل انتخاب ویژگی و رگرسیون استفاده می‌شود. در مراجع [۳] و [۶] از مجموعه داده AMPds^۴ برای پیاده‌سازی الگوریتم‌های پیش‌بینی استفاده شده است. در این مقاله نیز از نسخه دوم همین مجموعه داده برای نشان‌دادن کارایی روش پیشنهادی استفاده شده است تا امکان مقایسه نتایج به‌دست‌آمده با یکدیگر باشد. روش تحلیل اجزای مجاور، روشی مبتنی بر قانون نزدیک‌ترین همسایه است. روش پیشنهادی در این مقاله، طرح انتخاب ویژگی به روش تحلیل اجزای مجاور برای حل مسئله رگرسیون خطی در قالب مسئله بهینه‌سازی است. روش مدنظر برای حل مسئله طرح‌شده، روش LBFSGS است که روشی برای حل مسئله بهینه‌سازی در مباحث یادگیری ماشین است.

در ادامه، در بخش دوم، مسئله انتخاب ویژگی برای رگرسیون به روش تحلیل اجزای مجاور و روش حل آن ارائه شده است. در بخش سوم، نتایج شبیه‌سازی ارائه شده‌اند و مقایسه‌ای میان نتایج به‌دست‌آمده با سایر

شبکه برق برای عملیاتی همچون کاهش پیک بار ممکن می‌شود.

در بسیاری از کشورها سیستم‌های قدرت سنتی به سمت مدرن‌شدن در قالب شبکه‌های هوشمند پیش می‌روند. در این کشورها زیرساخت‌های اندازه‌گیری پیشرفته در شبکه‌های توزیع در مناطق مسکونی وجود دارد. بر مبنای اندازه‌گیری‌های انجام‌شده، می‌توان بسیاری از عملیات‌ها را در سیستم‌های قدرت آینده انجام داد؛ عملیاتی همچون تجمع توان تولیدشده از انرژی‌های نو با شبکه اصلی و مدیریت سمت تقاضا که در سیستم‌های قدرت در آینده حائز اهمیت‌اند. برخلاف بار الکتریکی در سطح سیستم قدرت، مصرف برق خانگی معمولاً دارای نوسانات بالایی است و این باعث می‌شود پیش‌بینی بار مبتنی بر اندازه‌گیری برای یک مصرف‌کننده منفرد بسیار چالش‌برانگیز باشد.

در زمینه پیش‌بینی بار به پژوهش انجام‌شده در مرجع [۲] اشاره می‌شود. در این مرجع، روشی چهاربخشی با هدف پیش‌بینی بار و قیمت برق ارائه شده است. در بخش اول از تبدیل موجک گسسته برای ریزسازی سیگنال اصلی با حفظ اطلاعات با ارزش استفاده شده است. بخش دوم از مدل الگوریتم انتخاباتی فازی برای انتخاب بهترین داده‌ها با بیشترین ارتباط و کمترین تکرار بهره می‌گیرد و بخش سوم یک موتور پیش‌بینی‌کننده براساس سیستم چندورودی چندخروجی بردار پشتیبان است. در نهایت، بخش چهارم با توجه به تابع هدفی متشکل از خطای ناشی از پیش‌بینی و روش بهبودیافته کلسونی مصنوعی زنبورعسل به تنظیم شاخص‌های شبکه بردار پشتیبان پیشنهادی می‌پردازد.

اگرچه پژوهش‌های فراوانی در زمینه پیش‌بینی بار انجام شده است، مراجع اندکی در زمینه پیش‌بینی بار مبتنی بر اندازه‌گیری وجود دارد. در زمینه پیش‌بینی بار براساس اندازه‌گیری‌های انجام‌شده برای یک مصرف‌کننده به مطالعه انجام‌شده در مرجع [۳] اشاره می‌شود. در این مرجع، روشی مبتنی بر سری‌های زمانی کاربردی و در مرجع [۴] از تخمین‌زننده‌ای براساس فیلتر کالمن برای پیش‌بینی بار مسکونی استفاده شده است. نقطه‌ضعف این مراجع نبود مقایسه بین نتایج به‌دست‌آمده در آنها با روش‌های پیش‌بینی دیگر است. در مرجع [۵] بار مسکونی با استفاده از

روش‌های پیش‌بینی، انجام و نتیجه‌گیری پژوهش در بخش چهارم ارائه شده است.

۲- تحلیل اجزای مجاور برای رگرسیون

با ظهور داده‌های با ابعاد بالا و کاربردهای مختلفی مانند بازیابی اطلاعات، طبقه‌بندی خودکار متن، شیمی ترکیبی و بیوانفورماتیک، انتخاب ویژگی در داده‌کاوی^۵ (DM) و یادگیری ماشین^۶ (LM) اهمیت بیشتری پیدا کرده است [۹]. انتخاب ویژگی تکنیک انتخاب زیرمجموعه کوچک از مجموعه مشخصی از ویژگی‌ها با از بین بردن ویژگی‌های بی‌ربط و زائد است. انتخاب مناسب ویژگی‌ها نه تنها با کاهش ابعاد ویژگی‌ها مقدار داده‌های به‌کاررفته در مرحله یادگیری را کم می‌کند، اثر سوء ابعاد بالای داده‌ها را برای بهبود عملکرد تعمیم یا لگوریتم‌ها کاهش و سرعت اجرای مدل‌ها را افزایش می‌دهد. به‌طور کلی، الگوریتم‌های انتخاب ویژگی معمولاً در یکی از سه دسته زیر قرار می‌گیرند [۱۰]: فیلتر^۷، وارپر^۸ و روش‌های چندبخشی^۹.

در مدل فیلتر، انتخاب ویژگی با ارزیابی زیرمجموعه ویژگی با توابع معیار مشخص‌کننده خصوصیات ذاتی داده‌های آموزش، مانند فاصله بین داده‌های در هر دسته (مثل امتیاز فیشر)، معیارهای آماری (مانند مربع چسبی^{۱۰}) و معیارهای نظری اطلاعات انجام می‌شود که شامل بهینه‌سازی عملکرد هر طبقه‌بندی خاص به‌طور مستقیم نیست. در مقابل، دو روش دیگر به الگوریتم‌های دسته‌بندی مشخصی وابسته‌اند و در بیشتر موارد، بهتر از روش‌های فیلتر عمل می‌کنند. مدل وارپر برای انتخاب ویژگی‌ها به یک دسته‌بندی‌کننده نیاز دارد و از عملکرد آن برای ارزیابی میزان شایستگی زیرمجموعه‌های ویژگی انتخاب‌شده استفاده می‌کند. با توجه به اینکه دسته‌بندی‌کننده باید برای هر زیرمجموعه ویژگی مدنظر آموزش داده شود، روش وارپر از نظر محاسباتی فشرده است؛ بنابراین، بیشتر برای حل مسائل انتخاب ویژگی در مقیاس بزرگ مناسب نیست. در مدل چندبخشی، انتخاب ویژگی در ساختار دسته‌بندی‌کننده قرار می‌گیرد و معمولاً از روش شیب نزولی^{۱۱} (GD) برای

بهینه‌سازی وزن ویژگی‌ها استفاده می‌شود که نشان‌دهنده ارتباط بین ویژگی‌های مربوطه و هدف (دسته مدنظر در مسائل دسته‌بندی و مقدار عددی مدنظر در مسائل رگرسیون) است. مزیت این روش در کم‌تر بودن احتمال وقوع overfit و نیز موثرتر بودن آن نسبت به روش وارپر است [۱۱]. در آموزش نظارت‌شده به حفظ ورودی‌ها و خروجی‌ها به جای یادگیری آنها overfit گفته می‌شود.

نزدیک‌ترین همسایه^{۱۲} یک قانون تصمیم‌گیری غیرخطی ساده و کارآمد است و بیشتر در مقایسه با روش‌های دسته‌بندی پیشرفته مانند ماشین‌های بردار پشتیبان^{۱۳} (SVM) و شبکه‌های عصبی، نتایج رقابت‌پذیری ارائه می‌دهند. الگوریتم انتخاب ویژگی تحلیل اجزای مجاور (NCA) یک روش غیر پارامتری و چندبخشی برای انتخاب ویژگی‌ها با هدف حداکثر کردن دقت پیش‌بینی در مسائل رگرسیون و دسته‌بندی است [۱۰].

۱-۲- رگرسیون

رگرسیون روشی مستقیم برای پیش‌بینی یک مقدار عددی (Y) براساس متغیر پیش‌بینی‌کننده (X) است. مسئله رگرسیون به‌صورت زیر بیان می‌شود [۱۱]:

$$Y = \beta_0 + \beta_i X_i \quad (1)$$

β_0 و β_i مقادیری ثابت‌اند که به‌ترتیب پارامترهای رهگیری و شیب نامیده می‌شوند. مجموعه β_0 و β_i ‌ها با نام ضرایب مدل شناخته می‌شوند. در روش رگرسیون، در ابتدا بخشی از مجموعه داده‌ها به عنوان داده‌های آموزش در نظر گرفته می‌شوند. مجموعه داده‌های آموزش برای تخمین زدن مقدار ضرایب مدل استفاده می‌شوند. سپس برای انجام پیش‌بینی با استفاده از داده‌های جدید، مجموعه ضرایب تخمین زده شده در مرحله آموزش استفاده می‌شوند.

$$y_{ij} = \begin{cases} 1 & \text{if \&only if } y_i = y_j \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

اکنون فرض کنید \hat{y}_i مقدار عددی پاسخی باشد که مدل رگرسیون تصادفی پیش‌بینی می‌کند و y_i پاسخ واقعی برای x_i باشد، تابع تلفات $l: \mathbb{R}^2 \rightarrow \mathbb{R}$ به شکلی تعریف می‌شود که بیان‌کننده تطابق نداشتن y_i و \hat{y}_i باشد. مقدار میانگین $l(y_i, \hat{y}_i)$ برابر است با:

$$l_i = E(l(y_i, \hat{y}_i) | S^{-i}) = \sum_{j=1, j \neq i}^N p_{ij} l(y_i, \hat{y}_i) \quad (7)$$

پس از اضافه کردن پارامتر تنظیم، تابع هدف به‌منظور بهینه‌سازی برابر است با [۱۱]:

$$\xi(w) = \frac{1}{N} \sum_{i=1}^n l_i + \lambda \sum_{r=1}^p w_r^2 \quad (8)$$

۲-۳- حل مسئله

بسیاری از مسائل در مباحث یادگیری ماشین، یک مسئله بهینه‌سازی نامقید، غیرخطی و غیرمحدب به شکل زیرند [۱۳]:

$$\min_{w \in \mathbb{R}^M} f(w) \quad (9)$$

که در آن f_i تابعی از مشاهده i ام در مجموعه داده‌های آموزش (مانند مجموعه S) است. از رابطه (۹) با عنوان ریسک تجربی^{۱۴} نیز یاد می‌شود. این نوع از مسائل دارای ویژگی‌های بسیاری‌اند که به موجب آنها الگوریتم‌های بهینه‌سازی مرسوم برای حل آنها موثر نیستند. اول آنکه مقادیر M و N در رابطه (۹) مقادیر بسیار بزرگی‌اند (به‌طور معمول $M, N \geq 10^6$) و دوم آنکه نوع خاصی از افزونگی در رابطه (۹) وجود دارد که به دلیل شباهت بسیاری از نقاط داده‌های آموزش یکدیگر است.

هدف مرحله بهینه‌سازی، به‌دست آوردن بهترین مجموعه وزن‌های ممکن به طوری است که تابع به‌دست‌آمده برای مدل پیش‌بینی $p(x, w)$ ، مقدار متغیر هدف \mathcal{L} را با بالاترین دقت ممکن پیش‌بینی کند. دو روش بهینه‌سازی پرکاربرد در یادگیری ماشین روش‌های نزول شیب تصادفی^{۱۵} (SGD) و حافظه محدود BFGS یا به

۲-۲- انتخاب ویژگی برای مسئله رگرسیون

فرض کنید مجموعه $S = \{(x_1, y_1), \dots, (x_N, y_N)\}$ مجموعه‌ای از نمونه‌های آموزشی باشد؛ به طوری که x_i برداری d -بعدی از ویژگی‌ها، مقادیر پاسخ‌ها $y_i \in \mathbb{R}$ است و N تعداد نمونه‌ها باشد. هدف پیش‌بینی پاسخ (یعنی y) است که در مجموعه S ارائه شده است. یک مدل رگرسیون تصادفی به شکل زیر را در نظر بگیرید [۱۲]:

۱- مدل رگرسیون به‌طور تصادفی یک نقطه از S را به‌عنوان نقطه مرجع برای نقطه x $Ref(x)$ انتخاب می‌کند.

۲- مقادیر پاسخ در نقطه x برابر با مقادیر پاسخ در نقطه‌ی مرجع‌اند.

فاصله وزنی بین دو نمونه x_i و x_j برابر است با:

$$D_w(x_i, x_j) = \sum_{l=1}^d w_l^2 |x_{il} - x_{jl}| \quad (2)$$

در اینجا w_l وزن مربوط به ویژگی l ام است. احتمال انتخاب نقطه x_j از مجموعه S به‌عنوان نقطه مرجع برای نقطه x برابر با رابطه زیر است:

$$p_{ij} = \begin{cases} \frac{\kappa(D_w(x_i, x_j))}{\sum_{\kappa \neq i} \kappa(D_w(x_i, x_j))}, & \text{if } i \neq j \\ 0, & \text{if } i = j \end{cases} \quad (3)$$

$$\kappa(z) = e^{-\frac{z^2}{\sigma}} \quad (4)$$

$\kappa(z)$ یک تابع کرنل است و σ بیان‌کننده اندازه کرنل و یک پارامتر ورودی است که بر احتمال انتخاب هر یک از نقاط به‌عنوان نقطه مرجع تأثیر می‌گذارد. به‌ویژه اگر $\sigma \rightarrow 0$ میل کند، فقط نزدیک‌ترین همسایه به نمونه مدنظر می‌تواند به‌عنوان نقطه مرجع انتخاب شود. همچنین اگر $\sigma \rightarrow +\infty$ میل کند، تمامی نقاط به جز نقطه مدنظر، برای انتخاب شدن از شانس مساوی برخوردارند. با فرض اینکه این مدل رگرسیون تصادفی قرار است در عملکرد کاربرد $Leave-One-Out$ استفاده و پاسخ x_i با استفاده از داده‌های S^{-i} پیش‌بینی شود، احتمال آنکه نقطه x_j به‌عنوان نقطه مرجع x_i انتخاب شود، از رابطه زیر به دست می‌آید.

$$p_i = \sum_j p_{ij} y_{ij} \quad (5)$$

می‌شود. این الگوریتم مانند الگوریتم نزول شیب تصادفی فقط به گرادیان مرتبه اول نیاز دارد. روش‌های شبه - نیوتون تکرارهایی را با استفاده از قانون زیر تولید می‌کنند:

$$w_{k+1} = w_k + \zeta_k p_k \quad (11)$$

$$p_k \propto -B_k^{-1} \nabla f(w_k) \quad (12)$$

B_k ماتریس شبه - نیوتون است که در هر تکرار با استفاده از گرادیان به‌روز می‌شود و ζ_k نرخ یادگیری است. به‌روزرسانی B_k با استفاده از ترتیبی از بردارها انجام می‌شود که به‌صورت زیر تعریف می‌شوند:

$$s_j \propto w_{j+1} - w_j, j = 0, \dots, k-1 \quad (13)$$

$$y_j \propto \nabla f(w_{j+1}) - \nabla f(w_j), j = 0, \dots, k-1 \quad (14)$$

به‌روزرسانی به روش برویدن^{۱۷} با استفاده از پارامتر $\phi \in \mathbb{R}$ تعریف می‌شود که به‌طور وسیعی برای به‌روزرسانی B_k استفاده شده است:

$$B_{k+1} = B_k - \frac{1}{s_k^T B_k s_k} B_k s_k s_k^T B_k + \frac{1}{y_k^T s_k} y_k y_k^T + \phi (s_k^T B_k s_k) y_k y_k^T \quad (15)$$

$$v_k = \frac{y_k}{y_k^T s_k} - \frac{B_k s_k}{s_k^T B_k s_k} \quad (16)$$

در عمل B_0 یک اسکالر مثبت در نظر گرفته می‌شود. در بهینه‌سازی در مقیاس بزرگ، روش‌های شبه - نیوتون با حافظه محدود برای محدود کردن نیازهای ذخیره‌سازی و ارتقای بهره‌وری استفاده می‌شوند. در اینجا تنها r جفت آخر محاسبه‌شده از $\{(s_j, y_j)\}$ برای محاسبه B_{k+1} استفاده می‌شود؛ بدین معنی که فقط به‌روزترین اطلاعات برای ساختن ماتریس هسیان استفاده می‌شوند. مقدار عددی r معمولاً بسیار کوچک است $r \ll N$.

ماتریس‌های دنباله $\{B_j\}$ متقارن ساخته می‌شوند و این درحالی است که انتخاب مقادیر متفاوت برای ϕ به تولید دنباله‌ای از ماتریس‌ها با مشخصات متفاوت منجر خواهد شد. معروف‌ترین عضو از مجموعه به‌روزرسانی برویدن، به‌روزرسانی (BFGS) است که با تنظیم مقدار ϕ برابر با صفر حاصل می‌شود. B_0 به‌دست‌آمده با این روش، مثبت معین است و نامساوی $y_i^T s_i > 0$ برای $i = 0, \dots, k-1$ برقرار است؛ در نتیجه به‌روزرسانی BFGS دنباله‌ای از

عبارتی LBFGS هستند. روش استفاده‌شده در این مقاله برای حل مسئله بهینه‌سازی ارائه‌شده در رابطه (۹) استفاده از روش نزول شیب تصادفی همراه با پیاده‌سازی روش LBFGS روی دسته‌های بسیار کوچک (Mini-batches) است.

۱-۳-۲- نزول شیب تصادفی


همان‌طور که گفته شد روش نزول شیب تصادفی [۱۴] یکی از روش‌های مرسوم برای حل مسائل یادگیری ماشین است. در این روش در هر تکرار، یک اندیس مانند j به‌طور تصادفی از $\{1, 2, \dots, N\}$ انتخاب می‌شود و وزن‌هایش به شکل زیر به‌روزرسانی می‌شوند [۱۳]:

$$w = w - \zeta_j \nabla f_j(w) \quad (10)$$

∇f_j بیان‌کننده گرادیان f_j است و ζ_j بیان‌کننده نرخ یادگیری است. به دلایل بسیاری، روش نزول شیب تصادفی، روشی جذاب در مباحث یادگیری ماشین است. اول آنکه این روش افزودنی مطرح‌شده در داده‌ها را به کار می‌گیرد و دوم آنکه پیچیدگی تکرارها مستقل از N (تعداد مشاهدات موجود در مجموعه داده آموزش) است؛ برخلاف الگوریتم‌های بهینه‌سازی کلاسیک که به N بستگی دارند و در هنگام تلاش برای بهره‌برداری از تقریب‌های تصادفی ساده‌تر شیب، ناپایدار می‌شوند [۱۶، ۱۵]. همچنین این الگوریتم نظریه همگرایی جذابی دارد [۱۸، ۱۷]. سوم آنکه الگوریتم نزول شیب تصادفی به‌آسانی به یک محیط یادگیری آنلاین پاسخ می‌دهد (یعنی داده‌ها به‌صورت ترتیب در دسترس‌اند) که ممکن است در آن مشاهدات موجود در داده‌ها هرگز تکرار نشوند [۱۹]. مزیت چهارم در تنظیمات غیر محذب این الگوریتم است. ماهیت تصادفی این روش نسبت به روش‌های غیرتصادفی کمتر باعث می‌شود پاسخ نهایی به مینیمم‌های محلی همگرا شود [۲۰، ۲۱].

۲-۳-۲- الگوریتم LBFGS

الگوریتم LBFGS یکی از پرکاربردترین الگوریتم‌های کلاسیک در مباحث یادگیری ماشین است که جزو الگوریتم‌های شبه - نیوتون^{۱۶} با حافظه محدود محسوب



شکل (۱): دیاگرام داده‌های استفاده‌شده در این مطالعه

داده‌های ورودی، جریان‌های اندازه‌گیری شده از بخش‌های مختلف خانه و وسایل برق آن شامل سوئیچ اجاره (RSE)، گاراژ (GRE)، بخش اصلی خانه (MHE)، اتاق خواب شمالی (B1E)، پریزهای زیرزمین و روشنایی (BME)، ماشین لباسشویی (CWE)، ماشین ظرفشویی (DWE)، تجهیزات امنیتی (شبکه) (EQE)، پنکه و ترموستات کوره HVAC (FRE)، پمپ حرارتی (HPE)، دفتر کار در خانه (OFE)، اتاق تجهیزات (UTE)، فر دیواری (WOE)، اتاق خواب مستر (جنوبی) (B2E)، خشک‌کن لباس (CDE)، نهارخوری (DNE)، میز کار الکترونیک (EBE)، یخچال (FGE)، واحد آب گرم فوری (HTE)، پریزهای بیرون خانه (OUE)، اتاق تلویزیون (TVE) و باقیمانده مصارف اندازه‌گیری شده با کنتور کلی (UNE) هستند.

۲-۵- ارزیابی دقت پیش‌بینی

برای محاسبه دقت پیش‌بینی انجام شده، راه‌های مختلفی وجود دارد. ارزیابی پیش‌بینی‌ها در این مقاله به کمک سه شاخص میانگین مربعات خطا^{۱۹} (MSE)، جذر میانگین مربعات خطا^{۲۰} (RMSE) و میانگین مطلق درصد خطا^{۲۱} (MAPE) انجام می‌شود. این شاخص‌ها بارها در پژوهش‌های مختلف استفاده شده‌اند و معیاری برای مقایسه نتایج به دست آمده با استفاده از روش‌های مختلف‌اند. شاخص‌های میانگین مربعات خطا و جذر میانگین مربعات خطا با استفاده از روابط زیر محاسبه می‌شوند:

$$MSE(i) = \frac{1}{n} \sum_{i=1}^n (A_i - F_i)^2 \quad (16)$$

ماتریس‌های مثبت معین را تولید می‌کند. شرط جستجوی خطی ولف^{۱۸} برای محاسبه y_i در رابطه (۱۰) منجر شود.

یکی از دلایلی که به‌روزرسانی BFGS را به به‌روزرسانی ارجح تبدیل می‌کند، این است که این روش، یک روش کارآمد برای حل سیستم‌های خطی با Bk است و محاسبه pk در رابطه (۱۱) را ممکن می‌کند [۲۲]. روش LBFSG مزایای بسیاری دارد. اول آنکه محاسبه $\nabla f(w)$ از طریق یک محیط برنامه‌نویسی موازی ممکن می‌شود. دوم آنکه تعداد اندکی از هاپر - پارامترها وجود دارند که کاربرد آنها را تنظیم می‌کند؛ مانند تعداد وزن‌ها و مقیاس‌دهی ماتریس اولیه B0 و مقداردهی اولیه استاندارد که در بهینه‌سازی استفاده می‌شوند؛ به این معنا که در روش LBFSG نیازی به تنظیم دستی پارامترها نیست.

۲-۶- داده‌ها

در این مقاله برای اجرای روش پیشنهادی و مقایسه با سایر روش‌های پیش‌بینی، نسخه دوم مجموعه داده‌های AMPds استفاده شده است [۲۳]. در این مجموعه داده، جریان‌های الکتریکی (برحسب آمپر) و توان مصرفی (برحسب کیلووات - ساعت) یک خانه در کانادا به صورت دقیقه‌ای برآید و سال کامل ثبت شده‌اند.

با توجه به نظارت شده بودن روش پیشنهادی در این مقاله، نیاز است تا ماتریس ورودی و بردار شامل خروجی‌های مطلوب برای محاسبه وزن‌های رگرسیون تعیین شوند. در این مقاله از داده‌های جریان‌های اندازه‌گیری شده به عنوان ورودی برای پیش‌بینی مصرف برق استفاده شده است. خروجی مطلوب در این کار، مجموع توان‌های مصرفی محاسبه شده برای خانه مدنظر است. ماتریس‌های ورودی و خروجی به صورت نیم‌ساعته مرتب شده‌اند تا بتوان توان مصرفی را در بازه‌های نیم‌ساعته پیش‌بینی کرد. شکل (۱) دیاگرام داده‌های استفاده‌شده در این مقاله را نمایش می‌دهد.

هدفی شامل خطاهای پیش‌بینی در هر مرحله است. برای تکمیل مقایسه نتایج، نتایج روش پیشنهادی با روش مرجع [۲۴] نیز مقایسه خواهند شد.

$$RMSE(i) = \sqrt{\frac{\sum_{i=1}^n (A_i - F_i)^2}{n}} \quad (17)$$

شاخص میانگین مطلق درصد خطا نیز به صورت زیر تعریف می‌شود:

$$MAPE(i) = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100 \quad (18)$$

در روابط (۱۶) تا (۱۸)، A_i مقدار واقعی بار و F_i مقدار پیش‌بینی شده و n تعداد پیش‌بینی‌های انجام شده است.

۶-۲- روش‌های مقایسه


برای انجام مقایسه بین روش پیشنهادی در این مقاله با روش‌های دیگر، شش روش در نظر گرفته شده است. این روش‌ها عبارت‌اند از: رگرسیون خطی چندگانه، رگرسیون مقاوم، درخت تصمیم‌گیری، درخت تصمیم‌گیری تقویت‌شده، جنگل تصادفی و ماشین بردار پشتیبان. درباره مدل رگرسیون خطی در بخش (۲-۱) بحث شد. رگرسیون مقاوم در اینجا رگرسیون خطی چندگانه است که فاکتور قطع^{۲۲} به آن اضافه شده است. به دلیل اینکه حل مسائل رگرسیون با استفاده از روش‌های درختی معمولاً نتایج خوبی ارائه می‌دهند، این روش‌ها نیز برای انجام مقایسه انتخاب شده‌اند. روش‌های درختی مبتنی بر طبقه‌بندی یا تقسیم‌بندی فضای پیش‌بینی‌کننده به تعداد منطقه ساده‌تر است. به منظور پیش‌بینی یک مشاهده خاص، معمولاً از میانگین پاسخ‌های پیش‌بینی شده استفاده می‌شود. با توجه به اینکه مجموعه‌ای از قوانین تقسیم‌بندی برای تقسیم فضای پیش‌بینی‌کننده‌ها در یک درخت خلاصه می‌شوند، این نوع روش‌ها روش درخت تصمیم شناخته می‌شوند. در این مقاله، سه روش درخت تصمیم‌گیری، درخت تصمیم‌گیری تقویت‌شده و جنگل تصادفی از مجموعه روش‌های یادگیری درختی برای انجام مقایسه استفاده شده‌اند.

روش دیگر به کار گرفته شده برای مقایسه، رگرسیون ماشین بردار پشتیبان است. ماشین بردار پشتیبان، روشی مبتنی بر استفاده از تابع کرنل است. حل مسئله رگرسیون به روش رگرسیون ماشین بردار پشتیبان شامل حداقل کردن تابع

۳- نتایج شبیه‌سازی

شبیه‌سازی در دو بخش و از طریق کدنویسی در محیط نرم‌افزار متلب ۲۰۱۹ در سیستمی با پردازشگر core i5-8250U، رم ۸ گیگابایتی و در محیط ویندوز ۱۰ انجام شده است. این دو بخش عبارت‌اند از: آموزش و آزمایش. در بخش آموزش، ضرایب رگرسیون پیش‌بینی می‌شوند و اعتبارسنجی با استفاده از روش اعتبارسنجی k -فولد، در بخش آزمایش از داده‌های جدید پیش‌بینی‌های نیم‌ساعته تولید می‌شوند. اعتبارسنجی از مدل‌ها در بخش آموزش و از طریق اعتبارسنجی ۱۰-فولد^{۲۳} انجام می‌شود. برای ارزیابی روش پیشنهادی، نتایج به دست آمده با استفاده از روش پیشنهادی با نتایج شش روش دیگر مقایسه می‌شوند.

با توجه به بخش داده‌ها، مجموعه داده‌های AMPDs2 برای پیاده‌سازی روش ارائه شده در این مقاله استفاده شده است. در این مقاله ۶۰ درصد از داده‌ها برای آموزش مدل‌ها (تخمین ضرایب) و ۴۰ درصد باقی‌مانده به دو بخش تقسیم شده و برای انجام پیش‌بینی میان‌مدت استفاده شده است. نتایج استفاده از روش پیشنهادی در این مقاله برای یافتن ضرایب رگرسیون برای ۱۰۰۰ تکرار در شکل (۲) نمایش داده شده‌اند. محور عمودی در این نمودار نشان‌دهنده میانگین مربعات خطا است. بهترین مقدار میانگین مربعات خطای به دست آمده با استفاده از روش پیشنهادی در تکرار ۱۷۳ به دست آمده که مقدار آن برابر بار ۷۳/۱۲ kWh است. شکل (۳) ضرایب به دست آمده برای ویژگی‌ها [ستون‌های ماتریس داده‌های ورودی مطابق با شکل (۱)] و شکل (۴) باقیمانده پیش‌بینی‌ها در مرحله آموزش را نمایش می‌دهد. نتایج آموزش به روش پیشنهادی در این مقاله و روش‌های مقایسه در جدول (۱) نمایش داده شده‌اند. با توجه به جدول (۱)، نتایج ارائه شده در مرحله آموزش نشان‌دهنده سرعت پایین‌تر روش پیشنهادی در مرحله آموزش است. میانگین مطلق درصد خطای به دست آمده




شکل (۳): ضرایب رگرسیون به‌دست‌آمده با استفاده از روش

پیشنهادی

شکل‌های (۵) و (۷) نتایج پیش‌بینی با استفاده از روش پیشنهادی و روش‌های مقایسه و شکل‌های (۶) و (۸) باقیمانده پیش‌بینی‌های انجام‌شده را نشان می‌دهند که تفاضل مقادیر مشاهده‌شده و پیش‌بینی‌شده از توان مصرفی‌اند. در شکل‌های (۴) الی (۸)، هر یک نتایج به‌دست‌آمده از بخش‌های روی محور افقی با استفاده از روش پیشنهادی و روش‌های مقایسه در بازه‌های زمانی نیم‌ساعته برای کل دوره پیش‌بینی نشان داده شده‌اند. همان‌طور که دیده می‌شود روش پیشنهادی، خطای کمتری نسبت به سایر روش‌های مقایسه‌شده دارد.

نسبت به روش جنگل تصادفی ۲/۳۱۶۴ درصد پایین‌تر است که دقت بالاتر روش پیشنهادی را نشان می‌دهد.

در مرحله بعد با استفاده از هر یک از مجموعه داده‌های آزمایش، پیش‌بینی میان‌مدت انجام می‌شود. هر یک از مجموعه‌های آزمایش شامل ۱۴۶ روز است که پیش‌بینی بار در بازه‌های نیم‌ساعته را ممکن می‌سازد. نتایج پیش‌بینی برای هر یک از زیرمجموعه داده‌های آموزش در شکل‌های (۵) تا (۸) و جدول‌های (۲) و (۳) نمایش داده شده‌اند.




شکل (۲): روند یافتن ضرایب رگرسیون با استفاده از روش

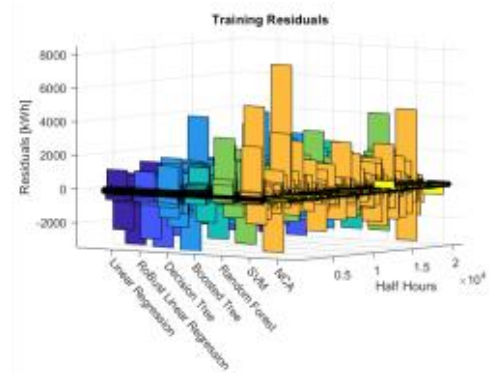
پیشنهادی در ۱۰۰۰ تکرار

جدول (۱): نتایج آموزش مدل‌های پیش‌بینی

زمان پیش‌بینی (s)	MAPE (%)	RMSE (kWh)	MSE (kWh)	روش
۸/۳۸۵	۴/۶۷۵۷	۱۱۶/۳۷	۱۳۵۴۲	رگرسیون خطی
۷/۳۹۷	۴/۳۹۴۱	۱۱۹/۱۹	۱۴۲۰۶	رگرسیون مقاوم
۴	۲/۴۱۵۴	۸۷/۲۵۱	۷۶۱۲/۸	درخت تصمیم‌گیری
۶/۶۴۶	۵/۵۵۷۲	۱۸۰/۰۷	۳۲۴۲۶	درخت تصمیم‌گیری تقویت شده
۱۰/۳۷۹	۲/۸۶۸۴	۱۳۰/۸۷	۱۷۱۲۶	جنگل تصادفی
۸۲	۴/۵۱۸۲	۳۳۱/۹۶	۱۱۰۲۰۰	ماشین بردار پشتیبان
۷۵/۶	۰/۵۰۲۷	۱۸/۱۱۴	۳۲۸/۱۲	روش پیشنهادی

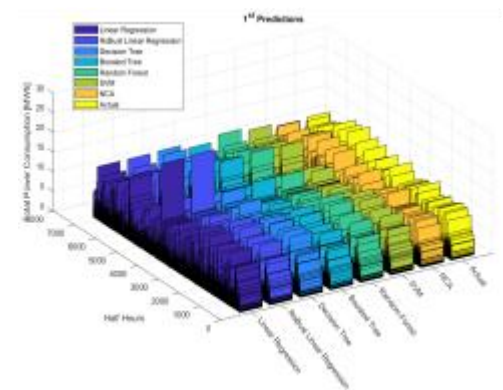


شکل (۷): نتایج پیش‌بینی با استفاده از مجموعه آزمایش دوم




شکل (۴): باقیمانده پیش‌بینی‌ها در مرحله آموزش

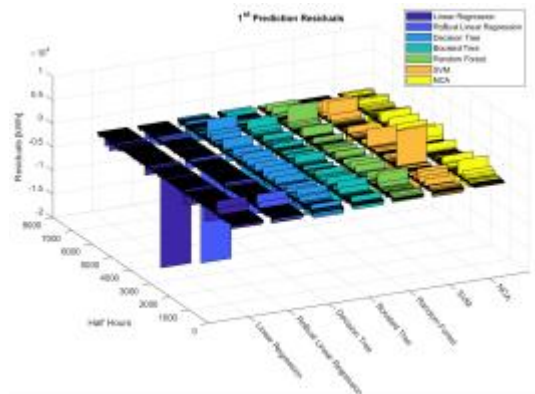
نتایج ارائه‌شده در جدول (۲) نیز ثابت می‌کنند استفاده از روش ارائه‌شده که مبتنی بر استخراج ویژگی به روش تحلیل اجزای مجاور و حل مسئله رگرسیون است، روشی مناسب و دارای خطای اندک برای پیش‌بینی بار خانگی است.



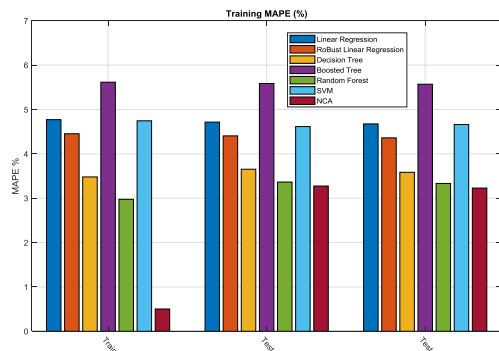
شکل (۵): نتایج پیش‌بینی با استفاده از مجموعه آزمایش اول



شکل (۸): باقیمانده پیش‌بینی‌ها با استفاده از مجموعه آزمایش دوم




شکل (۶): باقیمانده پیش‌بینی‌ها با استفاده از مجموعه آزمایش اول



شکل (۹): نتایج خطای MAPE بر حسب درصد

پیشنهادی برای پیش‌بینی بار خانگی به مقدار ۲۲/۴۸ کیلووات ساعت نتیجه بهتری از روش درخت تصمیم‌گیری ارائه داده است. شکل (۹) نتایج خطای MAPE محاسبه شده برای هر یک از روش‌های مقایسه را در مراحل آموزش و آزمایش نمایش می‌دهد. همان‌طور که در این شکل مشاهده می‌شود روش پیشنهادی در این مقاله خطای کمتر را نسبت به روش‌های مقایسه ارائه می‌دهد.

برای مقایسه نتایج به دست آمده با سایر کارهای انجام شده در زمینه پیش‌بینی بار خانگی، نتایج پیش‌بینی برای یک روز با نتایج مرجع [۲۴] مقایسه شده‌اند. در این مرجع نیز مانند این مقاله از داده‌های AMPds برای شبیه‌سازی استفاده شده است و داده‌ها به‌طور مشابه به بازه‌های ۳۰ دقیقه‌ای تقسیم شده‌اند. تنها تفاوت داده‌های استفاده شده در مرجع مذکور با مطالعه انجام شده در این مقاله در تعداد داده‌های در نظر گرفته شده است؛ به این ترتیب که داده‌های ماشین لباس‌شویی، ماشین ظرف‌شویی، پمپ حرارتی، فر دیواری (W/OE)، خشک‌کن لباس (CDE) و اتاق تلویزیون (TVE) برای آموزش آزمایش مدل‌های پیش‌بینی استفاده شده‌اند. باید توجه داشت در مرجع [۲۴] پیش‌بینی کوتاه‌مدت انجام شده است؛ به همین دلیل، نتایج پیش‌بینی برای روز ۱۵ مارس ۲۰۱۳ با نتایج به دست آمده با استفاده از شبکه عصبی LSTM پیشنهاد شده در مرجع [۲۴] مقایسه شده‌اند. شکل (۱۰) نتایج پیش‌بینی برای روز ۱۵ مارس ۲۰۱۳ را با استفاده از روش پیشنهادی در این مقاله و روش ارائه شده در مرجع [۲۴] و جدول (۴) خطای محاسبه شده برای این روز نمایش می‌دهند.



شکل (۱۰): پیش‌بینی بار خانگی برای روز ۱۵ مارس ۲۰۱۳

جدول (۲): نتایج آزمایش با استفاده از مجموعه آزمایش ۱

زمان پیش‌بینی	MAPE (%)	RMSE (kWh)	MSE (kWh)	روش
۰/۰۲۳	۴/۷۲۱۶	۱۲۹/۱۵	۱۶۶۸۰	رگرسیون خطی
۰/۰۲۳	۴/۴۲۶۱	۱۳۲/۲۵	۱۷۴۹۱	رگرسیون مقاوم
۰/۰۱۰	۳/۶۵۸	۱۹۸/۵	۳۹۴۰۱	درخت تصمیم‌گیری
۰/۰۳۶	۵/۸۰۶	۲۰۱	۴۰۴۰۲	درخت تصمیم‌گیری تقویت شده
۰/۰۷۵	۳/۲۷۸	۱۶۸/۳۵	۲۸۳۴۲	جنگل تصادفی
۰/۳۱۶	۴/۷۱۰	۱۷۷/۴۲	۳۱۴۷۹	ماشین بردار پشتیبان
۲/۴۸۳	۳/۲۷۴	۱۶۶/۱۷	۲۸۲۹۹	روش پیشنهادی

جدول (۳): نتایج آزمایش با استفاده از مجموعه آزمایش ۲

زمان پیش‌بینی	MAPE (%)	RMSE (kWh)	MSE (kWh)	روش
۰/۰۱۸۷	۴/۷۶۲	۲۶۳/۳۸	۶۹۳۶۹	رگرسیون خطی
۰/۰۲۱	۴/۴۴۶	۲۶۹/۰۸	۷۲۴۰۲	رگرسیون مقاوم
۰/۰۱۴	۳/۶۸۳	۲۱۵/۸۹	۴۶۶۱۰	درخت تصمیم‌گیری
۰/۰۳۶	۵/۷۷۰	۲۲۰/۲۷	۴۸۵۱۸	درخت تصمیم‌گیری تقویت شده
۰/۰۷۱	۳/۳۲۳	۱۶۶/۱۹	۲۷۶۱۹	جنگل تصادفی
۰/۳۱۳	۴/۶۸۱	۱۷۴/۳	۳۰۳۸۰	ماشین بردار پشتیبان
۰/۰۰۶	۳/۲۲۹	۱۴۳/۷۱	۲۰۶۵۲	روش پیشنهادی

نتایج حاصل از این روش با اختلاف کمی بهتر از روش رگرسیون جنگل تصادفی‌اند که روشی با خطای بسیار پایین است. بررسی شاخص جذر میانگین مربعات خطا در پیش‌بینی مجموعه آزمایش دوم نیز ثابت می‌کند روش

نتایج محاسبه خطای MAPE که نشان‌دهنده درصد متوسط خطا در کل طول بازه پیش‌بینی است، نشان‌دهنده کارایی روش پیشنهادی در پیش‌بینی بار خانگی است.

جدول (۴): نتایج پیش‌بینی روز - پیش

MAPE (%)	RMSE (kWh)	MSE (kWh)	
۹/۸۸۶۶	۲۲۲/۳۲	۴۹۴۲۵	LSTM
۳/۳۹۱۲	۱۰۵/۱۹	۱۱۰۶۵	روش پیشنهادی

مراجع

- [1] N. Nazeri, M. Moazzami, G. Shahgholian, "A hybrid approach for mid-term electricity price forecasting based on support vector machine and neural networks", Computational Intelligence in Electrical Engineering, Vol. 9, No. 2, pp. 41-54, Summer 2018 (Persian).
- [2] H. Shayeghi, A. Ghasemi, "Modeling of multi input multi output based LSSVM for electricity price and load forecasting in smart grid with considering demand side management", Computational Intelligence in Electrical Engineering, Vol. 6, No. 4, pp. 87-106, Winter 2016 (Persian).
- [3] M. Chaouch, "Clustering-based improvement of nonparametric functional time series forecasting: Application to intra-day household-level load curves", IEEE Trans. on Smart Grid, Vol. 5, pp. 411-419, 2014.
- [4] M. Ghofrani, M. Hassanzadeh, M. Etezadi-Amoli, M. S. Fadali, "Smart meter based short-term load forecasting for residential customers", Proceeding of the IEEE/NAPS, pp. 1-5, Boston, MA, USA, Aug. 2011.
- [5] S. Humeau, T. K. Wijaya, M. Vasirani, K. Aberer, "Electricity load forecasting for residential customers: Exploiting aggregation and correlation between households", 2013 Sustainable Internet and ICT for Sustainability (SustainIT), 30-31 Oct. 2013.
- [6] B. Asare-Bediako, W. L. Kling, P. F. Ribeiro, "Day-ahead residential load forecasting with artificial neural networks using smart meter data", Proceeding of the IEEE/PTC, pp. 1-6, Grenoble, France, June 2013.
- [7] T. Hossen, A. S. Nair, R. A. Chinnathambi, P. Ranganathan, "Residential load forecasting using deep neural networks (DNN)", Proceeding of the IEEE/NAPS, pp. 1-5, Fargo, ND, USA, Sept. 2018.
- [8] W. Kong, Z. Yang Dong, Y. Jia, D. J. Hill, Y. Xu, Y. Zhang, "Short-term residential load forecasting based on lstm recurrent neural network", IEEE Trans. on Smart Grid, Vol. 10, No. 1, pp. 841 - 851, Jan. 2019.
- [9] H. Liu, E. Dougherty, J. Dy, K. Torkkola, E. Tuv, H. Peng, C. Ding, F. Long, M. Berens, L. Parsons et al., "Evolving feature selection", IEEE Intelligent Systems, Vol. 20, No. 6, pp. 46-76, 2005.
- [10] I. Guyon, S. Gunn, M. Nikravesh, and L. Zadeh, "Feature extraction: Foundations and applications", Springer-Verlag, 2006.
- [11] G. James, D. Witten, T. Hastie, R. Tibshirani, "An introduction to statistical learning with applications in R", Springer, 2013.
- [12] Yang, W., K. Wang, W. Zuo. "Neighborhood component feature selection for high-dimensional

نتایج ارائه شده نشان می‌دهند خطای به‌دست‌آمده با استفاده از روش پیشنهادی در این مقاله پایین‌تر از خطای به‌دست‌آمده با استفاده از روش ارائه‌شده در مرجع [۲۴] است که نشان می‌دهد روش پیشنهادی روش کارآمدی برای پیش‌بینی بار خانگی است.

۴- نتیجه‌گیری

پیش‌بینی میان‌مدت بار در مناطق مسکونی نقش مهمی در مدیریت و برنامه‌ریزی شبکه‌های هوشمند مدرن دارد. در برنامه‌ریزی برای متعادل نگه داشتن تولید و مصرف، لازم است تا پیش‌بینی دقیقی از بار مناطق مسکونی انجام شود. در این مقاله، روشی به‌منظور پیش‌بینی میان‌مدت بار مسکونی با استفاده از انتخاب ویژگی‌ها به روش تحلیل اجزای مجاور برای حل مسئله رگرسیون ارائه شده است. این روش مبتنی بر قانون نزدیک‌ترین همسایه است که در آن یک مسئله بهینه‌سازی مطرح شده است که استخراج ویژگی و تعیین وزن‌های مسئله رگرسیون خطی را در خود جای می‌دهد. اساس این روش، انتخاب وزن‌هایی برای هر یک از ستون‌های ماتریس ویژگی‌ها است که در آن ویژگی‌های کم‌اهمیت، وزن‌های کمتری را در مسئله رگرسیون به خود اختصاص می‌دهند. روش پیشنهادی برای حل مسئله بهینه‌سازی مطرح‌شده، استفاده از الگوریتم LBFGS است که در حل مسائل یادگیری ماشین با ابعاد بزرگ استفاده می‌شود. برای اجرای روش ارائه‌شده، مجموعه داده‌های AMPds2 استفاده شده است. نتایج به‌دست‌آمده با استفاده از روش پیشنهادی با نتایج شش روش دیگر شامل رگرسیون خطی، رگرسیون خطی قوی، درخت تصمیم‌گیری، درخت تصمیم‌گیری تقویت‌شده، جنگل تصادفی و ماشین بردار پشتیبان مقایسه شده‌اند. شاخص‌های MAPE, RMSE (kWh), MSE (kWh) (% به‌منظور مقایسه نتایج به‌دست‌آمده استفاده شده‌اند.

- Programming Computation", Vol. 7, No. 4, pp. 399-428, Dec 2015.
- [19] A. Choromanska, M. Hena, M. Mathieu, G. B. Arous, Y. LeCun, "The loss surface of multilayer networks", CoRR, 2014.
- [20] I. Guyon, R. Garnett, "Advances in neural information processing systems", Vol. 29, pp. 586-594. Curran Associates, Inc., 2016.
- [21] L. Sagun, V. U. Guney, Y. LeCun, "Explorations on high dimensional landscapes", Machine Learning, 2014.
- [22] J. Nocedal, "Updating quasi-newton matrices with limited storage Math", Mathematics of Computation, Vol. 35, No. 15, pp. 773-782, July 1980.
- [23] S. Makonin, F. Popowich, L. Bartram, B. Gill, I. V. Bajic, "AMPds: A public dataset for load disaggregation and eco-feedback research", Proceeding of the IEEE/EPEC, pp. 1-6, Halifax, NS, Canada, Aug. 2013.
- [24] W. Kong, Z. Yang Dong, D. J. Hill, F. Luo, Y. Xu, "Short-term residential load forecasting based on resident behaviour learning", IEEE Trans. on Power System, Vol. 33, No.1, pp. 1087-1088, Jan. 2018.
- data", Journal of Computers, Vol. 7, No. 1, Jan. 2012.
- [13] J. B. Erway, J. Griffin, R. F. Marcia, R. Omheni, "Trust-region algorithms for training responses: Machine learning methods using indefinite hessian approximations", Cornell University, 23 May 2019, arXiv:1807.00251.
- [14] H. Robbins and S. Monro., "A stochastic approximation method", The Annals of Mathematical Statistics, Vol. 22, No. 3, pp. 400-407, 1951.
- [15] L. Bottou, F. Curtis, J. Nocedal, "Optimization methods for large-scale machine learning", SIAM Review, Vol. 60, No. 2, pp. 223-311, 2018.
- [16] R. H. Byrd, S. L. Hansen, J. Nocedal, Y. Singer, "A stochastic quasi-newton method for large-scale optimization", SIAM Journal on Optimization, Vol. 26, No. 2, pp. 1008-1031, 2016.
- [17] F. Curtis, "A self-correcting variable-metric algorithm for stochastic optimization", Proceedings of The 33rd International Conference on Machine Learning, pp. 632-641, 2016.
- [18] F. E. Curtis, X. Que, "A quasi-newton algorithm for nonconvex, nonsmooth optimization with global convergence guarantees", Mathematical

¹ Long-Short-Term Memory

² Neighborhood Component Analysis

³ Limited Memory Broyden-Fletcher-Goldfarb-Shanno

⁴ Almanac of Minutely Power Dataset

⁵ Data Mining

⁶ Machine Learning

⁷ Filter

⁸ Wrapper

⁹ Embedded

¹⁰ Chi-square

¹¹ Gradient Descent

¹² Nearest Neighbor

¹³ Support Vector Machines

¹⁴ Empirical Risk

¹⁵ Stochastic Gradient Descent

¹⁶ Quasi-Newton

¹⁷ Broyden

¹⁸ Wolf Line Search

¹⁹ Mean Squared Error

²⁰ Root Mean Squared Error

²¹ Mean Absolute Percentage Error

²² Interception Factor

²³ Fold Cross-Validation