

Presenting a New Model of Electric Power Consumption Estimation Based on Parallel Wavelet Converters and Convolutional Neural Networks with Deep Learning for Residential Buildings

Nasser Kurd¹, Farshid keynia²

¹Department of Computer Engineering, Kerman Branch, Islamic Azad University, Kerman, Iran

kurd.nasser@gmail.com

²Energy Department, International Center for Science, High Technology & Environmental Sciences, Kerman, Iran

f.keynia@kgut.ac.ir

Abstract:

Considering the increasing rate of electrical energy usage, this energy has become one of the most important resources for human life. So all countries are seeking access to reliable and planned energy resource. Regarding the non-renewability of fossil fuel resources, especially oil and gas, the issue of replacing these types of energy with renewable energy has been considered for decades. Saving and optimal use of electrical energy in important applications such as residential and commercial buildings is critical. One of the most important factors for planning power consumption and optimizing it is accurate forecasting for next hours' power consumption of residential and commercial buildings. In this paper, first, the data sets of several residential buildings are analyzed using parallel wavelet converters. Then, using an optimal estimator model of the convolutional neural network, the short-term load of the building is estimated. The obtained results show that the proposed method has improved the prediction error about 70, 69 and 73 percent for ARIMA, SVR, and LSTM methods, respectively.

Keywords: Power Consumption Prediction, Energy Consumption Management, Convolutional Neural Networks, Wavelet Transform, Deep Learning.

ارائه مدل جدید تخمین مصرف انرژی بر اساس مبدل‌های موجک موازی و شبکه‌های عصبی کانولوشن با یادگیری عمیق برای ساختمان‌های مسکونی

ناصر کرد^۱، فرشید کی‌نیا^۲

۱- گروه مهندسی کامپیوتر، واحد کرمان - دانشگاه آزاد اسلامی - کرمان - ایران

kurd.nasser@gmail.com

۲- گروه مدیریت و بهینه‌سازی انرژی، پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی - دانشگاه

تحصیلات تکمیلی صنعتی و فناوری‌های پیشرفته - کرمان - ایران

f.keynia@kgut.ac.ir

چکیده: با توجه به افزایش میزان مصرف برق، این انرژی یکی از مهم‌ترین منابع برای زندگی انسان است؛ بنابراین، همه کشورهای به دنبال دسترسی به منابع انرژی مطمئن و برنامه‌ریزی شده هستند. نیز با توجه به تجدیدناپذیر بودن منابع سوخت‌های فسیلی به‌ویژه منابع نفت و گاز، چندین دهه است موضوع جایگزین‌سازی این نوع انرژی‌ها با انرژی‌های تجدیدپذیرشایان توجه قرار گرفته است. صرفه‌جویی و مصرف بهینه انرژی الکتریکی در مصارف مهم مانند ساختمان‌های مسکونی و تجاری اهمیت زیادی دارد. یکی از مهم‌ترین عوامل برای برنامه‌ریزی مصرف برق و بهینه‌سازی آن، پیش‌بینی دقیق برای مصرف برق ساختمان‌های مسکونی و تجاری در آینده است. در این مقاله، ابتدا با استفاده از مبدل‌های موازی موجک، مجموعه داده‌های چند ساختمان مسکونی تحلیل می‌شوند، سپس با استفاده از مدل بهینه تخمین‌گر شبکه عصبی کانولوشن برق مصرفی کوتاه‌مدت ساختمان‌پیش‌بینی می‌شوند. نتایج پژوهش نشان می‌دهند روش ارائه شده به‌طور متوسط خطای تخمین روش‌های ARIMA، شبکه عصبی LSTM و SVR را به ترتیب ۶۹، ۷۰ و ۷۳ درصد بهبود بخشیده است.

واژه‌های کلیدی: پیش‌بینی مصرف برق، مدیریت مصرف انرژی، شبکه‌های عصبی کانولوشن، تبدیل موجک، آموزش عمیق.

۱- مقدمه

و مؤسسات تحقیقاتی مختلف، اعم از دولتی و خصوصی، برای انجام پژوهش‌ها در زمینه برنامه‌ریزی مصرف انرژی و صرفه‌جویی و بهینه‌کردن آن تأسیس شده‌اند و در واقع انرژی، یکی از مسائل مهم و استراتژیک در اقتصاد ملل جهان شده است. مدیریت مصرف انرژی الکتریکی به دو صورت مدیریت بار الکتریکی و بهینه‌سازی مصرف انرژی اعمال پذیر است. نظر به اینکه در ایران در ساعات اولیه شب، وسایل روشنایی و لوازم الکترونیکی خانگی وارد مدار می‌شود، بار مصرفی به حداکثر مقدار خود می‌رسد و مدیریت مصرف برای کاهش این پیک بار و تعدیل آن باید برخی از مصارف را به ساعات دیگر شبانه‌روز انتقال دهد. در این راستا از مهم‌ترین فعالیت‌های مؤثر، پیش‌بینی دقیق میزان مصرف انرژی در ساعات آینده برای برنامه‌ریزی کاهش مصرف و تأمین انرژی لازم از منابع انرژی

مدیریت و بهینه‌سازی مصرف انرژی، یکی از مهم‌ترین اهداف کشورهای مختلف برای صرفه‌جویی در مصرف انرژی، کاهش آلودگی محیط زیست و استقلال کشور از واردات حامل‌های انرژی است. برای این منظور در کشورهای مختلف، به‌ویژه کشورهای صنعتی، ارگان‌ها

^۱ تاریخ ارسال مقاله: ۱۳۹۸/۰۴/۰۵

تاریخ پذیرش مقاله: ۱۳۹۸/۱۱/۰۸

نام نویسنده مسئول: فرشید کی‌نیا

نشانی نویسنده مسئول: کرمان - کرمان - دانشگاه تحصیلات تکمیلی صنعتی و فناوری‌های پیشرفته - پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی

تجدیدپذیر در دسترس است.

امروزه روش‌های متفاوتی برای پیش‌بینی انرژی مصرفی ساختمان‌ها ارائه شده‌اند. از این جمله روش‌های کمی و کیفی‌اند که در روش‌های کمی عمده هدف پیدا کردن یک مدل و مبنای ریاضی برای ترسیم رفتار آینده سیستم است که این مدل با روش‌های مختلف ریاضی یا روش‌های شناسایی سیستم، تخمین زده می‌شود [۱] و معمولاً از روش‌های سری زمانی یا روش‌های علت و معلولی استفاده می‌شود. در مدل‌های سری زمانی، عمده هدف تأکید بر این قضیه است که تعدادی از پدیده‌ها و متغیرها در سیستم‌های مختلف وجود دارند که با یک روند خاص رشد می‌کنند؛ اگر این روند بر مبنای تکرار در دوره‌های زمانی در نظر گرفته شود، مدل آینده سیستم بر حسب روند قبلی پیش‌بینی می‌شود. به عبارت دیگر، یک سری زمانی دنباله‌ای از مشاهدات منظم شده بر حسب زمان از یک متغیرند که با تجزیه و تحلیل آن مدلی برای تخمین مقادیر آینده سیستم به وجود می‌آید. مدل‌های علت و معلولی، بیان‌کننده یک مدل بین سری زمانی متغیر پیش‌بینی شده و متغیرهای دیگر است که در به وجود آمدن این سری زمانی نقش دارند. هدف، پیدا کردن یک مدل ریاضی و سیستمی است که این رابطه را به طور منطقی برقرار کند. روش‌های پیش‌بینی کیفی، بیشتر برای سیستم‌هایی به کار می‌روند که مدل ریاضی ندارند و یا مدل احتمالی آنها پیچیده و کاملاً غیرخطی است و به آسانی نمی‌توان با روش‌های کلاسیک ریاضی به این مدل رسید و در صورت رسیدن به این مدل ریاضی، دقت زیادی نخواهد داشت یا هزینه بر خواهد بود. در این روش با استفاده از طرح و نظر افراد متخصص در سیستم مدنظر، آینده سیستم با توجه به گذشته، حال و آینده آن، با تعدادی قوانین پایه توصیف می‌شود و بر اساس آن، کمیت مدنظر برای آینده پیش‌بینی می‌شود؛ البته امروزه با توسعه سیستم‌های هوشمند، کاربرد این روش‌ها در پیش‌بینی سری‌های زمانی به طور چشمگیری افزایش یافته‌اند.

برای تخمین مصرف برق خانگی دو چالش بزرگ وجود دارد که عبارت‌اند از:

- نوسان شدید میزان مصرف برق: میزان مصرف برق در هر خانه در دنیای واقعی به رفتار انسان بستگی دارد و

رفتار انسان قابلیت پیش‌بینی دشواری دارد؛ به همین علت پیش‌بینی سری‌های زمانی مربوط به مصرف برق خانگی پیچیدگی‌های خاص خود را دارد.

- تک‌متغیره بودن داده ورودی: برای پیش‌بینی مصرف برق خانگی و آموزش یک مدل، تنها متغیر ورودی، مقدار برق مصرفی در گذشته بر حسب کیلو وات بر ساعت است؛ یعنی تخمین‌گر برای پیش‌بینی مصرف برق، تنها باید از روی رفتار گذشته همین متغیر، عمل تخمین را انجام دهد و متغیر کمکی دیگری نخواهد داشت.

در سال‌های اخیر شبکه‌های عصبی یادگیری عمیق پیشرفت‌های چشمگیری در علم کامپیوتر داشته‌اند. شبکه‌های عصبی یادگیری عمیق در زمینه‌های پردازش زبان طبیعی [۲]، تشخیص اشیا در تصویر [۳]، تحلیل سری‌های زمانی [۴] و بهبود دقت و پایداری سیستم‌های مکان‌یابی پیشرفت‌های چشمگیری ایجاد کرده‌اند. شبکه‌های عصبی حافظه طولانی کوتاه‌مدت ($LSTM^1$) نشان داده‌اند در تخمین مصرف برق خانگی از دقت زیادی برخوردارند [۵-۶-۷]. نتایج آزمایشگاهی نشان داده‌اند شبکه‌های $LSTM$ به‌تنهایی، دقت زیادی نسبت به روش‌های آماری تخمین مانند [$ARIMA^8$] و رگرسیون بردار پشتیبانی (SVR^9) دارند [۹]. همچنین شبکه‌های عصبی $LSTM$ از شبکه‌های عصبی مصنوعی غیر عمیق در تخمین قدرتمندترند [۱۰]. دلیل این امر وابستگی‌های زمانی نسبت به برش‌های زمانی همسایه است که در گیت‌های حافظه در شبکه‌های عصبی بازگشتی (RNN^4) وجود دارد [۱۱]. در واقع شبکه‌های عصبی $LSTM$ یک فرم ویژه و تغییر یافته شبکه‌های عصبی بازگشتی‌اند که مشکل ناپدید شدن (صفر شدن) گرادیان را با اضافه کردن دروازه فراموشی حل می‌کنند [۱۲]؛ اما شبکه‌های عصبی $LSTM$ به‌ویژه در معماری‌های عمیق در طول فرآیند آموزش (مثلاً بیش از ۳ لایه) دچار مشکل $Overfitting$ می‌شوند. این مشکل چالشی در یادگیری است که در معماری عمیق شبکه‌های عصبی رخ می‌دهد. در واقع اگر تعداد لایه‌های شبکه عصبی بدون توجه به خطای مرحله ارزیابی افزایش یابد، خطای پیش‌بینی بیشتر خواهد شد. این مطلب به وضوح در [۱۳] به صورت آزمایشگاهی اثبات شده است.

متفاوت که شامل لایه‌های مختلف است و در ساخت و بهینه سازی وزن‌ها نتایج مطلوبی داشته است.

- شبکه‌های عصبی LSTM در فرآیند یادگیری عمیق به داده‌های بسیار متنوعی نیاز دارند تا رفتار کلی مصرف برق را یاد گرفته و پیش‌بینی کنند؛ اما مدل ارائه شده در این مقاله قادر است حتی با استفاده از رفتار گذشته یک منزل مسکونی با دقت زیادی میزان مصرف برق برای ساعات آینده همان خانه را پیش‌بینی کند. به عبارت دیگر، تخمین‌گر ارائه شده در این مقاله برای پیش‌بینی دقیق میزان مصرف برق، به داده‌های متنوع (برای مثال، میزان برق مصرفی همسایگان) برای آموزش شبکه عصبی خود نیازی ندارد.

- تخمین برق مصرفی برای ۵ خانه در دنیای واقعی انجام شده است که نتایج آزمایشگاهی حکایت از دقت بالای روش ارائه شده دارد. پیش‌بینی دقیق مصرف برق خانگی برای برنامه ریزی بهتر خانه‌های هوشمند بسیار درخور استفاده و مفید است.

۲- کارهای مرتبط

پیش‌بینی مصرف برق یک مسئله سنتی است که از چندین دهه قبل تا به امروز مطالعه و پژوهش شده است. از جمله روش‌های تخمین مرسوم غیر آماری، روش SVR، شبکه‌های عصبی مصنوعی، روش‌های منطق فازی [۱۶] هستند. از روش‌های تحلیلی سری زمانی نیز رگرسیون خودکار میانگین متحرک [ARIMA(۱۷)]، روش ARIMA با استفاده از متغیرهای خارجی [۱۸] و مدل‌های [Gray ۱۹] هستند. Yuan و همکارانش [۸] با ترکیب روش ARIMA و Gray توانسته‌اند به روشی بهتر دست یابند که میانگین خطای مطلق آن کمتر از دو روش مذکور است.

در مقاله [۲۰] برای پیش‌بینی مصرف برق در ترکیب از دو روش SVR و شبکه عصبی مصنوعی استفاده شده که پس از ارزیابی خطای MAPE روش SVR با اختلاف ۰/۶ درصد عملکرد بهتری نسبت به شبکه عصبی مصنوعی داشته است. Rodrigues و همکارانش [۲۱] یک مدل شبکه عصبی برای تخمین مصرف انرژی طراحی کرده‌اند که دارای یک لایه مخفی با ۶۰ نرون است. آنها انرژی مصرفی

همچنین شبکه‌های عصبی LSTM به داده‌های بسیار متنوعی برای آموزش نیاز دارند تا پیش‌بینی دقیقی انجام دهند. شبکه‌های عصبی کانولوشن در سال‌های اخیر پیشرفت چشمگیری در حوزه بینایی ماشین به وجود آورده است؛ برای مثال، با استفاده از این شبکه‌ها، استخراج ویژگی‌های تصویر به صورت مطلوبی انجام گرفته است. همچنین شبکه‌های عصبی کانولوشن یک بعدی به منزله عملگر مفید برای پیش‌پردازش و استخراج ویژگی از داده‌ها در سری‌های زمانی است [۱۴].

در این پژوهش یک روش ترکیب‌سازی عمیق با استفاده از موجک موازی ارائه شده است. سری‌های زمانی مصرف برق خانگی، ابتدا با موجک شکسته می‌شوند و سپس به عنوان ورودی به شبکه عصبی عمیق فرستاده می‌شوند. شبکه عصبی با یک لایه کانولوشن ویژگی‌های داده را استخراج می‌کند، سپس با استفاده از بهینه‌ساز، مراحل آموزش شبکه و تنظیم وزن‌ها انجام می‌شود.

برای ارزیابی عملکرد تخمین‌گر ارائه شده در این مقاله از ۵ مجموعه داده استفاده شد. این مجموعه داده‌ها مصرف واقعی برق خانگی ۵ خانه در شهر لندن اند [۱۵]. همچنین تخمین‌گر ارائه شده با روش‌های مرسوم تخمین مانند SVR، ARIMA و شبکه عصبی LSTM مقایسه شده است. مقایسه این روش‌ها با معیارهای میانگین خطای مطلق (MAE^0)، ریشه میانگین خطای مربع ($RMSE^1$) و درصد میانگین خطای مطلق ($MAPE^2$) اندازه‌گیری شده است. نتایج نشان می‌دهند ترکیب موجک موازی با شبکه عصبی کانولوشن، تخمین بسیار دقیق‌تری از روش‌های یاد شده را داراست.

نوآوری‌های انجام شده در این پژوهش به صورت ذیل خلاصه می‌شوند:

- ارائه یک روش شکستن سیگنال جدید با موجک موازی که مراحل تخمین را برای شبکه عصبی کانولوشن آسان‌تر می‌سازد.

- غلبه بر عدم قطعیت شدید مجموعه داده‌ها با استفاده از مدل موجک موازی که یادگیری برای شبکه عصبی حتی با داده‌های محدود را میسر می‌سازد.

- ارائه یک مدل ترکیبی آموزش شبکه عصبی کانولوشن

بار یک روش ترکیبی از موجک موازی با شبکه عصبی تکاملی ارائه شده است. روش ارائه شده در این مقاله با روش تخمین SVR و شبکه عصبی چند لایه مقایسه شده که توانسته است معیارهای خطا را به میزان مطلوبی کاهش دهد.

Kong و همکارانش [۷] یک شبکه عصبی LSTM دو لایه ارائه کرده‌اند که برای پیش‌بینی مصرف برق خانگی استفاده شده است. سپس نتایج خود را با روش‌های شبکه عصبی انتشار به عقب (BPNN^۹)، رگرسیون K تا نزدیک‌ترین همسایه (KNN^{۱۰}) و یادگیری ماشین مفرط (EML^{۱۱}) مقایسه کرده‌اند. نتایج نشان دادند شبکه LSTM دو لایه، تخمین بسیار دقیق‌تری نسبت به روش‌های مذکور داشته است.

۳- ساختار سیستم ارائه شده

برای تخمین سری‌های زمانی تک‌متغیره که دارای نوسان شدید در بازه زمان‌اند، یک شبکه عصبی کانولوشن با توانایی یادگیری عمیق ارائه شده است. به‌طور کلی مراحل تخمین طبق سلسله‌مراتب زیر نوشته می‌شوند:

(ا) ابتدا مجموعه داده‌ها، نرمال‌سازی، سپس به دسته‌های آموزش و آزمایش تقسیم می‌شوند.

(ب) با استفاده از تبدیل چندمرحله‌ای موجک، داده‌های آموزش و آزمایش به زیر مجموعه‌های کوچک‌تر تقسیم می‌شوند.

(ج) سیگنال‌های خروجی مرحله موجک به‌عنوان ورودی شبکه عصبی کانولوشن استفاده می‌شوند.

(د) سیگنال‌های موجک با شبکه عصبی کانولوشن تخمین زده می‌شوند. سپس مرحله موجک معکوس و پس‌پردازش روی آنها اعمال می‌شود تا سیگنال اصلی را بسازند.

۳-۱- مجموعه داده‌های استفاده شده

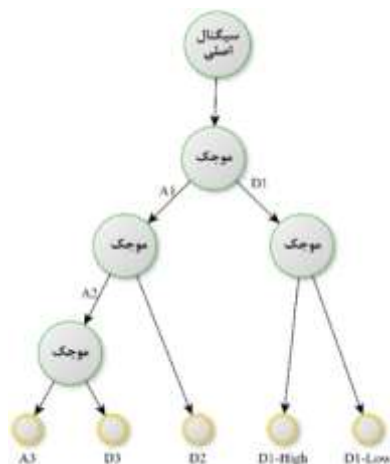
در این مقاله از مجموعه داده‌های مصرف برق جمع‌آوری شده آقای کلی و نوتنلت [۱۵] استفاده شده است. این مجموعه داده در بسیاری از مقالات معتبر مانند [۲۱] به‌منزله داده‌های آموزشی و آزمایشی شبکه‌های عصبی استفاده شده است. این مجموعه داده شامل برق مصرفی پنج

برای ۹۳ خانه را در کشور پرتغال پیش‌بینی کرده‌اند که میانگین خطای MAPE روش آنها روزانه ۴/۲ درصد بوده است. در مقاله [۲۲] آقای اماراتی و همکاران یک روش ترکیبی شبکه‌های عصبی با الگوریتم بهینه‌سازی ذرات ارائه داده‌اند که برای تخمین کوتاه‌مدت قیمت استفاده شده که در مقایسه با سایر روش‌های متداول تخمین، نتایج بهتری داشته است.

شبکه‌های عصبی یادگیری عمیق (DLNN^۸) مدرن و محبوب‌اند و با داده‌های آموزشی حجیم سروکار دارند. این شبکه‌ها در زمینه دسته‌بندی و تخمین به دقت بسیار زیادی دست یافته‌اند. در مقاله [۲۳] یک مدل شبکه عصبی کانولوشن ۲۴ ساعته ارائه شده که با استفاده از یادگیری عمیق توانسته است تخمین مصرف برق نسبت به روش فصلی ARIMAX را ۲۲,۶ درصد بهبود بخشد. همچنین در زمینه‌های متفاوتی مانند پیش‌بینی شاخص بازار بورس [۲۵,۲۴]، تخمین سرعت باد [۲۷,۲۶]، تخمین میزان تابش نور خورشید [۲۹,۲۸] و پیش‌بینی بار الکتریکی [۳۰] به کار رفته‌اند. در مقاله [۳۱] یک مدل یادگیری شبکه عصبی عمیق برای تخمین مصرف برق خانگی ارائه شده است. نتایج این مدل نشان می‌دهند دقت شبکه عصبی عمیق نسبت به روش‌های ARIMA، روش فصلی HoltCWinter و روش شبکه عصبی غیرعمیق، بالاتر است. Shi و همکاران [۶] یک شبکه عصبی بازگشتی بر اساس برون‌انداز (Dropout) ارائه داده‌اند که ابتدا عدم قطعیت میزان مصرف برق را ضبط و الگوبرداری می‌کند تا تخمین بهتری انجام دهد. نتایج این پژوهش نشان می‌دهند شبکه عصبی عمیق ارائه شده از روش‌های SVR، ARIMA و شبکه‌های عصبی بازگشتی عملکرد بهتری داشته است.

در [۳۲] یک روش تخمین قیمت با استفاده از ترکیب موجک موازی و اتصال چندین شبکه عصبی با مدل‌های یادگیری متفاوت ارائه شده است. همچنین از یک روش انتخاب ویژگی دو مرحله‌ای با توجه به وابستگی داده‌ها نسبت به متغیر هدف استفاده شده است. نتایج با روش ARIMA و روش ترکیبی موجک موازی با ARIMA مقایسه شده‌اند که روش ارائه شده معیارهای خطا را به طرز چشمگیری کاهش داده است. در [۳۳] برای پیش‌بینی متغیر

بهتری برای تخمین را فراهم می‌کند [۳۵]. شکل ۱ نحوه شکست سیگنال اصلیاژ موجک موچک موازی ارائه شده در این مقاله را نشان می‌دهد. توجه روش شکست سیگنال با جزئیات بیشتری در قسمت نتایج پژوهش بررسی شده است.



شکل (۱): مراحل شکستن سیگنال ورودیاز موجک چندمرحله‌ای

در مرحله اول شکستن، سیگنال اصلی به دو بخش جزئی (D1) و مقادیر تقریبی (A1) تقسیم می‌شود. در این کار موج D1 مجدد شکسته می‌شود. دلیل این امر سختی تخمین این موج است. با شکستن موج D1 به دو بخش D1-High و D1-Low تخمین موج اصلیعنی D1 دقیق‌تر شده است. پس از مراحل شکستن سیگنال، هر کدام از زیرموج‌های A3, D3, D2, D1-High و D1-Low به‌عنوان ورودی شبکه عصبی کانولوشن استفاده می‌شوند. پس از انجام تخمین شبکه عصبی، روی خروجی شبکه عصبی موجک معکوس اعمال می‌شود (شکل ۲) تا موج اصلی را بسازد.

۳-۳- شبکه عصبی کانولوشن

شبکه عصبی کانولوشن، یکی از مباحث داغ این روزهای هوش مصنوعیاست که قابلیت‌آدگیری عمیق برای مدل را فراهم می‌کند. در این روش برای تخمین موج‌های ورودی هر تخمین‌گر از شبکه عصبی کانولوشن استفاده شده است تا به کمک آن موج‌های دارای نوسان شدید، دقیق‌تر تخمین

خانه در شهر لندن است که به‌ترتیب با نام‌های Household1, Household2 تا Household5 شناخته می‌شوند. در مجموعه داده‌های مذکور، برق مصرفی براساس لوازم برقی (مانند ماشین لباسشویی، یخچال و ...) تفکیک شده‌اند. برق مصرفی لوازم خانگی در بازه‌های ۶ ثانیه‌ای ثبت شده است. در این مقاله از داده‌های تجمیع شده در بازه‌های زمانی ۵ دقیقه استفاده شده است. به عبارت دیگر، هر رکورد در مجموعه داده کل برق مصرفیک منزل مسکونی در بازه‌های زمانی ۵ دقیقه‌ای بر حسب کیلووات ساعت ($kWh^{۱۲}$) است.

۳-۲- مرحله شکست چندمرحله‌ای با سیگنال

موجک

تخمین سری‌های زمانیدارای نوسان شدید، کار دشواری است. با استفاده از موجک، سری‌های زمانی به زیرمجموعه‌های کوچک‌تری شکسته می‌شوند که تخمین هر کدام به دلیل نوسانان پایین‌تر از موج اصلی کاری نسبتاً آسان‌تر است. با توجه به اینکه مجموعه داده‌های استفاده شده دارای نوسان شدیدند، ابتدا با اعمال چندین مرحله موجک داده‌های مناسب‌تری برای مرحله تخمین آماده شد. سری‌های مصرف برق خانگی نیز دارای نوسان شدیدند؛ به همین دلیل، پیش‌بینی آنها کار دشواریاست. استفاده از موجک، سیگنال اصلی را به دو زیرمجموعه با فرکانس پایین و فرکانس بالا تقسیم می‌کند. تخمینا مطالعه موج اصلی به مراتب سخت‌تر از دوزیرمجموعه آن است. دلیل این امر اثر اعمال فیلترها روی موج اصلی و تبدیل آن به دو زیرمجموعه کوچک‌تر است [۱۷].

در این روش نیز ابتدا سیگنال اصلی طی چندین مرحله از تبدیل موجک عبور داده شد که آن را به بخش‌های جزئی و تقریبی تبدیل کرد. بخش تقریبی شامل روند کلی سیگنال اصلی و بخش جزئی نیز نوسانات شدید موج اصلی را در بر می‌گیرد [۳۴]. با استفاده از یک فرآیند شکستن چندمرحله‌ای موج اصلی به موج‌هایی با اندازه کوچک‌تر تبدیل شده که برای این کار از موجک Daubechies مرتبه ۴ استفاده شده است. استفاده از این موجک شرایط

بعضی از زیرموج‌های مشتق شده از موج اصلی پس از اشباع شبکه در صورت کاهش نرخ یادگیری وزن‌های بهتری، تولید و دوره‌های مفید بیشتری برای آموزش سپریمی‌کنند. برای این منظور در سیستم ارائه شده اگر شبکه پس از طی تعداد معینی دوره، نتواند خطای ارزیابی را کاهش دهد، به‌طور خودکار نرخ یادگیری را کاهش می‌دهد. فرآیند آموزش شبکه زمانی متوقف می‌شود که حتی با نرخ پایین یادگیری نتواند خطای مرحله ارزیابی را کاهش دهد. با این کار از تمام ظرفیت شبکه برای تخمین استفاده می‌شود.

۴- نتایج پژوهش

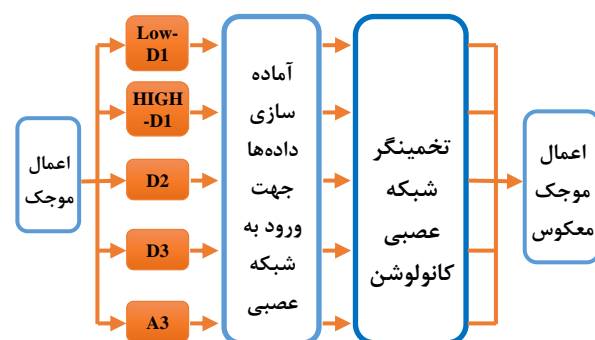
روش تخمین ارائه شده با استفاده از زبان برنامه‌نویسی پایتون Python 3.6 و در محیط برنامه‌نویسی Pycharm پیاده‌سازی شده است. مشخصات سخت‌افزاری سیستم شامل پردازشگر Inter Core-I7 2.5 GHz و پردازشگر گرافیکی NVIDIA GEFORCE 930mx است. طراحی مدل شبکه عصبی کانولوشن نیز با استفاده از ابزار یادگیری عمیق شرکت گوگل با نام [Tensorflow ۳۶] و [Keras ۳۷] انجام شده است. در بخش اول به توجیه نحوه شکستن موج اصلیا موجک پرداخته شد. پس از آن، در بخش دوم نتایج تخمین‌گر ساخته شده با روش‌های مرسوم تخمین، مقایسه خواهند شد.

۴-۱- توجیه نحوه شکستن سیگنال با موجک

برای ساده‌تر شدن مرحله تخمین و ساخت تخمین‌گری قوی‌تر، ابتدا سیگنال ورودی موجک به زیرموج‌های کوچک‌تری شکسته می‌شود که تخمین هر زیرمجموعه نسبت به موج اصلی آسان‌تر است. روش مرسوم شکستن سری زمانی با موجک در ۳ مرحله انجام می‌گیرد که ۴ خروجی با نام‌های D1, D2, D3 و A3 خواهد داشت و هر خروجی به یک تخمین‌گر برای تخمین فرستاده می‌شود [۳۱].

موج D1 شامل جزئیات نخستین مرحله از شکستن موج اصلیاست (شکل ۱). این زیرموج را مجدداً با موجک به D1-Low و D1-High شکسته می‌شود تا با جزئیات

زده شوند. لایه کانولوشن داده‌های خام را دریافت می‌کند. سپس ویژگی‌های منحصربه‌فرد آن را استخراج می‌کند. لایه‌های کانولوشن دارای فیلترهایی با اندازه $k*k$ و دو بعدی‌اند. در این مقاله به دلیل تک‌بعدی بودن ورودی‌ها از فیلترهایی با سایز $1*k$ استفاده شد. پس از استخراج ویژگی‌ها با لایه کانولوشن، داده‌ها به لایه‌های شبکه عصبی تماماً متصل فرستاده می‌شوند تا مراحل آموزش و تنظیم وزن‌ها انجام شوند. برای بهینه‌سازی وزن‌ها نیز از بهینه‌ساز Nesterov Adam Optimizer استفاده شد. این بهینه‌ساز ترکیبی از ترکیبی از RMSprop و Nesterov momentum است که به Nadam معروف است و قابلیت تنظیم نرخ یادگیری به صورت خودکار را دارد. در مرحله آموزش، پس از هر دوره اجرای شبکه همواره بهترین وزن‌ها ذخیره می‌شوند. بهترین وزن‌ها با توجه به کمترین میزان خطا در داده‌های ارزیابی انتخاب می‌شوند. به‌طور کلی فرآیند آموزش شبکه به صورت شکل ۳ است:



شکل (۲): ساختار کلی سیستم ارائه شده



شکل (۳): فرآیند آموزش تخمین‌گر استفاده شده برای هر موج

از یک لایه کانولوشن، دو لایه شبکه عصبی تماماً متصل (FCL^{۱۳})، یک لایه برون‌انداز (Dropout) با احتمال کم و در نهایت، لایه خروجی ساخته شده است.

استفاده شده است. در مرحله آزمایش، تخمین گر ابتدا تخمین برای بیش از ۱۰ ساعت آینده یعنی ۱۳۰ رکورد (۶۵۰ دقیقه) انجام شده است. برای تخمین هر پنج دقیقه بعدی دوازده رکورد قبلی آن یعنی یک ساعت قبل از آن، ورودی شبکه در نظر گرفته می شود. تخمین گر ارائه شده در این مقاله با روش های مرسوم تخمین مانند SVR, ARIMA و LSTM مقایسه شده است. دقت تخمین گر با سه معیار میانگین خطای مطلق (MAE)، ریشه میانگین خطای مربع (RMSE) و درصد میانگین خطای مطلق (MAPE) اندازه گیری شده است. در واقع هر چقدر میزان این سه معیار کمتر باشد، دقت تخمین بیشتر خواهد بود. رابطه های ۱ و ۲ و ۳ نشان دهنده معیارهای خطا هستند [۳۸].

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

$$MAE = \frac{\sum_{i=1}^N |\hat{y}_i - y_i|}{N} \quad (2)$$

$$MAPE = \frac{\sum_{i=1}^N |\hat{y}_i - y_i| \times 100}{N} \quad (3)$$

در این رابطه ها، y_i مقدار واقعی نمونه آزمایش و \hat{y}_i مقدار تخمین زده شده اند.

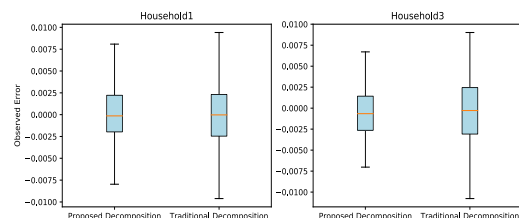
نمودار شکل ۵، نتایج را برای Household1 نشان می دهد. تفاوت دقت روش پیشنهادی با سایر روش های مقایسه شده در نمودار به خوبی مشخص می شود.

نمودارهای شکل های ۶، ۷، ۸ و ۹ نتایج تخمین مصرف برق خانگی برای Household های ۲ تا ۵ را به ترتیب با استفاده از روش های مذکور نشان می دهند. این نمودارها نتایج تخمین را در طول بازه های زمانی مختلفی نشان داده اند.

در هر یک از نمودارها خط مشکی نشان دهنده مقادیر واقعی، آبی روش پیشنهادی، نارنجی SVR، سبز ARIMA و قرمز LSTM است. همان گونه که در نمودار نشان داده شده است نتایج روش پیشنهادی در این مقاله کمترین میزان اختلاف با مقادیر واقعی را در طول نمودار از خود نشان می دهند؛ به ویژه در بازه های زمانی که مصرف برق دچار نوسانات ناگهانی می شود، روش پیشنهادی فاصله خود را با مقادیر واقعی حفظ می کند؛ در حالی که سایر روش ها با مقادیر مختلف از نمودار واقعی فاصله می گیرند.

دقیق تری تخمین زده شود. زمانی که زیرموج D1 به تنهایی به یک تخمین گر فرستاده می شود، با توجه به مقدار خطای مرحله ارزیابی از دقت پایینی برخوردار بود و در نتیجه، بر تخمین کلی تأثیر می گذاشت؛ اما پس از اینکه این زیرموج، مجدد شکسته شد و هر کدام جداگانه تخمین زده شدند، خطای مرحله ارزیابی کاهش نسبتاً خوبی پیدا کرد. این کاهش خطا در تخمین جزئیات موج اصلی کمک شایانی می کند؛ برای مثال، در نمودار شکل ۴، خطای تخمین برآید و مجموعه داده Household1 و Household3 به دو روش مرسوم و روش پیشنهادی شکستن سیگنال ارائه شده در این مقاله نمایش داده شده است. در ضمن ساختار شبکه برای هر دو حالت یکسان است. خطای MAPE تخمین برای Household1 با استفاده از روش مرسوم برابر با ۱۴/۲۷ است که پس از شکسته شدن موج D1 برابر با ۱۱/۳۱ شده که به میزان ۲/۹۶ واحد کاهش یافته است. همچنین برای دیتاست Household3 خطای MAPE با استفاده از روش مرسوم شکستن سیگنال برابر با ۷/۳۳ بوده است و هنگام استفاده از روش پیشنهادی، شکستن سیگنال برابر با ۵/۸۷ شده که ۱/۴۶ واحد کاهش داشته است. این دو مجموعه داده دارای نوسان شدیدتری نسبت به سایر مجموعه داده ها است. با توجه به نمودار شکل ۴، روش پیشنهادی شکستن سیگنال دامنه خطا را به مقدار چشمگیری کاهش داده و همچنین حدود خطا به صفر همگرا شده است.

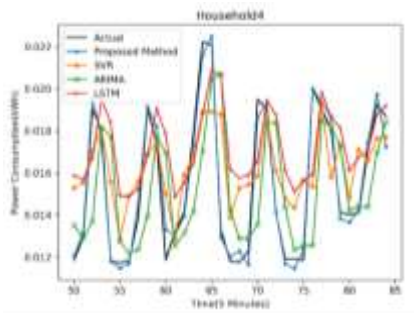
بنابراین روش شکستن موج ارائه شده در این مقاله (شکل ۱) برای تمام مجموعه داده ها استفاده شده است.



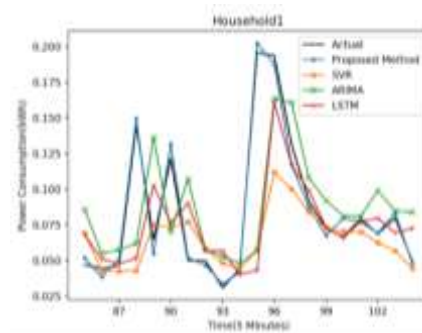
شکل (۴): مقایسه خطای تخمین با استفاده از روش مرسوم شکستن سیگنال و روش پیشنهادی

۴-۲- مقایسه و ارزیابی سیستم ارائه شده

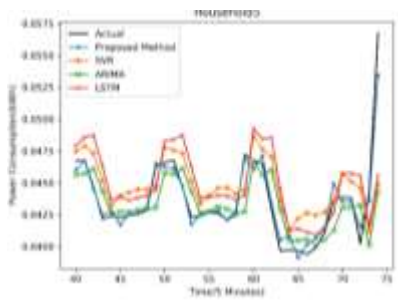
در هر مجموعه داده ۱۰۰۰۰ رکورد برای آموزش شبکه



شکل ۸: نمودار تخمین برای Household4



شکل (۵): نمودار تخمین Household1



شکل ۹: نمودار تخمین برای Household5

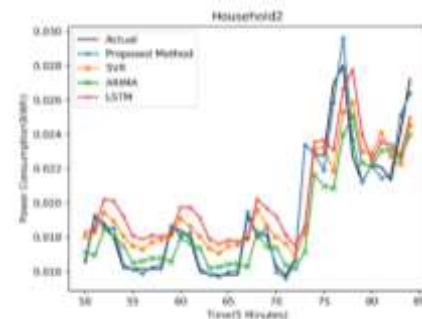
نتایج نشان می‌دهند سیستم پیشنهادی به صورت چشمگیری کلیه معیارهای خطا را کاسته است. صرف نظر از روش پیشنهادی، برای Household1 روش SVR نتایج بهتری را تولید می‌کند که خطای MAPE آن ۲۳/۲۴ است. خطای MAPE روش پیشنهادی ما روی این مجموعه داده برابر با ۱/۶ است که نسبت به SVR کاهش ۷۴٫۸۳٪ داشته است.

روش LSTM روی مجموعه داده Household1 دارای خطای RMSE برابر با ۰/۰۲۳۵ است که صرف نظر از روش پیشنهادی، کمترین میزای خطا را داراست. روش پیشنهادی ارائه شده، خطای RMSE برابر با ۰/۰۰۴۲ را تولید می‌کند که نسبت به روش LSTM کاهش ۸۱ درصدی داشته است.

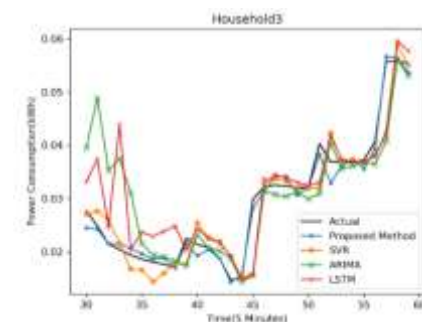
همچنین اگر میانگین هر یک از معیارهای خطا مدنظر قرار داده شود، به صورت کلی روش پیشنهادی با فاصله زیادی از سایر روش‌ها عملکرد مطلوب‌تری از خود نشان می‌دهد. جدول شماره ۱، نتایج اندازه‌گیری شده هر یک از معیارهای خطا را به تفکیک دیتاست‌های آزمایش شده نشان می‌دهند.

نمودار شکل‌های ۱۰، ۱۱ و ۱۲ خطای هر یک از روش‌ها برای Household های ۱، ۲ و ۴ را نشان می‌دهند. با مطالعه این نمودارها دریافته می‌شود که روش پیشنهادی به دلایل ذیل از دیگر روش‌های مطالعه شده در این مقاله برتر است:

- در کلیه دیتاست‌ها همگرایی خطای تخمین روش پیشنهادی به صفر بیشتر شده است. در واقع میزان خطای تخمین به صفر نزدیک‌تر شده است.



شکل (۶): نمودار تخمین برای Household2

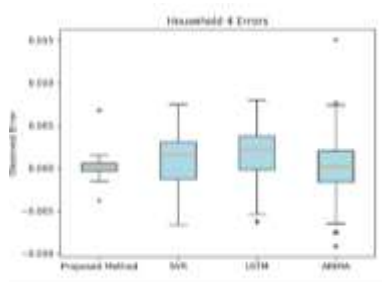


شکل ۷: نمودار تخمین برای Household3


- بازه نوسان مقادیر خطای تخمین روش پیشنهادی از محدوده ندارد یا تعداد اینگونه خطاها به نسبت چشمگیری نسبت به سایر روش‌ها کمتر شده است.
- روش پیشنهادی با خطای پرت (Outlier) خارج از

جدول (۱): نتایج معیارهای خطا برای روش‌های آزمایش شده

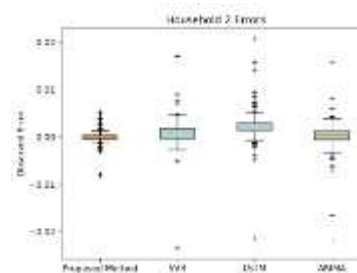
		Househo ld1	Househo ld2	Househo ld3	Househo ld4	Househo ld5	میانگین
R MSE	LSTM	۰,۰۲۲۶	۰,۰۰۴۳	۰,۰۳۴۰	۰,۰۰۳۵	۰,۰۰۶۲	۰,۰۱۴۱
	SVR	۰,۰۲۴۰	۰,۰۰۳۳	۰,۰۳۳۶	۰,۰۰۲۹	۰,۰۰۶۵	۰,۰۱۴۰
	ARIMA	۰,۰۲۳۵	۰,۰۰۳۵	۰,۰۳۵۷	۰,۰۰۳۷	۰,۰۰۶۴	۰,۰۱۴۵
	روش پیشنهادی	۰,۰۰۴۲	۰,۰۰۱۲	۰,۰۱۷۱	۰,۰۰۰۹	۰,۰۰۱۴	۰,۰۰۴۹
	LSTM	۰,۰۱۱۶	۰,۰۰۲۹	۰,۰۱۸۲	۰,۰۰۳۰	۰,۰۰۳۴	۰,۰۰۷۸
M AE	SVR	۰,۰۱۰۷	۰,۰۰۱۹	۰,۰۱۶۹	۰,۰۰۲۵	۰,۰۰۳۳	۰,۰۰۷۰
	ARIMA	۰,۰۱۲۲	۰,۰۰۲۰	۰,۰۱۸۶	۰,۰۰۲۷	۰,۰۰۲۹	۰,۰۰۷۶
	روش پیشنهادی	۰,۰۰۲۷	۰,۰۰۰۶	۰,۰۰۶۶	۰,۰۰۰۵	۰,۰۰۰۹	۰,۰۰۲۲
	LSTM	۲۶,۱۸۴۹	۱۳,۶۵۲۵	۱۸,۲۸۹۷	۱۹,۰۵۳۹	۷,۴۶۸۴	۱۶,۹۲۹ ۸
	M APE	SVR	۲۴,۲۳۸۲	۸,۹۸۵۸	۱۶,۹۷۲۹	۱۵,۹۵۵۲	۷,۰۷۳۶
ARIMA		۲۷,۵۷۷۳	۹,۳۶۵۶	۱۸,۶۸۹۵	۱۷,۱۶۷۲	۶,۲۴۷۱	۱۵,۸۰۹ ۵
روش پیشنهادی		۶,۱۰۰۶	۳,۱۶۳۸	۶,۷۱۸۶	۳,۶۸۷۶	۲,۰۵۲۵	۴,۳۴۴۶



شکل (۱۲): نمودار مقادیر خطا برای Household4



شکل (۱۰): نمودار مقادیر خطا برای Household1



شکل (۱۱): نمودار مقادیر خطا برای Household2

پیش‌بینی می‌کند. نتایج پژوهش نشان می‌دهند روش پیشنهادی با توجه به معیارهای خطا عملکرد بسیار بهتری نسبت به شبکه عصبی LSTM و سایر روش‌های مرسوم داشته است.

مراجع

- [1] J. Lago, F. De Ridder, and B. De Schutter, "Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms," *Applied Energy*, 2018.
- [2] R. Socher, C. C. Lin, C. Manning and A. Y. Ng, "Parsing natural scenes and natural language with recursive neural networks," in *Proceedings of the 28th international conference on machine learning (ICML-11)*, 2011, pp. 129-136.
- [3] L. Shao, Z. Cai, L. Liu, and K. Lu, "Performance evaluation of deep feature learning for rgb-d image/video classification," *Information Sciences*, Vol. 385, pp. 266-283, 2017.
- [4] T. Kuremoto, S. Kimura, K. Kobayashi, and M. Obayashi, "Time series forecasting using a deep belief network with restricted Boltzmann machines," *Neurocomputing*, Vol. 137, pp. 47-56, 2014.
- [5] W. Kong, Z. Y. Dong, D. J. Hill, F. Luo, and Y. Xu, "Short-term residential load forecasting based on resident behavior learning," *IEEE Transactions on Power Systems*, vol. 33, pp. 1087-1088, 2018.
- [6] H. Shi, M. Xu, and R. Li, "Deep learning for household load forecasting a novel pooling deep RNN," *IEEE Transactions on Smart Grid*, 2017.
- [7] W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu, and Y. Zhang, "Short-term residential load forecasting based on LSTM recurrent neural Network," *IEEE Transactions on Smart Grid*. 2017.
- [8] C. Yuan, S. Liu, and Z. Fang, "Comparison of China's primary energy consumption forecasting by using arima (the autoregressive integrated moving average) model and gm (1, 1) model," *Energy*, Vol. 100, pp. 384-390, 2016.
- [9] J. A. Suykens and J. Vandewalle, "Least squares support vector machine

جدول (۲): درصد بهبود روش ارائه شده نسبت روش‌های مرسوم

تخمین

MAPE	RMSE			
% ۷۷	% ۸۲	ARIMA	بهبود نسبت به (%)	واحد مسکونی شماره ۱
% ۷۴	% ۸۲	SVR		
% ۷۶	% ۸۱	LSTM		
% ۶۶	% ۶۵	ARIMA	بهبود نسبت به (%)	واحد مسکونی شماره ۲
% ۶۴	% ۶۳	SVR		
% ۷۶	% ۷۲	LSTM		
% ۶۴	% ۵۲	ARIMA	بهبود نسبت به (%)	واحد مسکونی شماره ۳
% ۶۰	% ۴۹	SVR		
% ۶۳	% ۴۹	LSTM		
% ۷۸	% ۷۵	ARIMA	بهبود نسبت به (%)	واحد مسکونی شماره ۴
% ۷۶	% ۶۸	SVR		
% ۸۰	% ۷۴	LSTM		
% ۶۷	% ۷۸	ARIMA	بهبود نسبت به (%)	واحد مسکونی شماره ۵
% ۷۰	% ۷۸	SVR		
% ۷۲	% ۷۷	LSTM		
% ۷۰	% ۷۰	ARIMA	میانگین بهبود نسبت به (%)	
% ۶۹	% ۶۸	SVR		
% ۷۳	% ۷۰	LSTM		

جدول شماره ۲ میزان بهبود معیارهای خطای MAPE و RMSE را با روش پیشنهادی نسبت به روش‌های SVR، ARIMA و LSTM به تفکیک هر یک از دیتاست‌ها نشان می‌دهد. میانگین بهبود معیار RMSE روش پیشنهادی ۶۹ درصد است. همچنین تخمین‌گر ارائه شده معیار MAPE را به طور متوسط نسبت به روش‌های مذکور ۷۱ درصد کاهش داده است.

۵- نتیجه‌گیری

در این پژوهش، یک مدل جدید یادگیری با استفاده از ترکیب موجک موازی و شبکه عصبی یادگیری عمیق کانولوشن ارائه شده است. پژوهش‌های اخیر نشان می‌دهند شبکه عصبی LSTM به‌تنهایی دقت زیادی در تخمین مصرف برق دارد [۵-۶-۷]؛ اما شبکه‌های عصبی LSTM برای پیش‌بینی دقیق، به داده‌های متنوع و حجیم برای آموزش نیاز دارند. روش ارائه شده، تنها با داده‌های یک منزل مسکونی با دقت مطلوبی مصرف برق آن را در آینده

- 1709-1716, 2010.
- [20] G. Oğcu, O. F. Demirel, and S. zaim, "Forecasting electricity consumption with neural networks and support vector regression," *Procedia-Social and Behavioral Sciences*, Vol. 58, pp. 1576-1585, 2012.
- [21] F. Rodrigues, C. Cardeira, and J. M. F. Calado, "The daily and hourly energy consumption and load forecasting using artificial neural network method: a case study using a set of 93 households in Portugal," *Energy Procedia*, Vol. 62, pp. 220-229, 2014.
- [22] M. Emarati, F. Keynia, A. Askarzadeh, "Application of hybrid neural networks combined with comprehensive learning particle swarm optimization to shortterm load forecasting", *Computational Intelligence in Electrical Engineering*, 10th year, No.1, 2019
- [23] M. Cai, M. Pipattanasomporn, and S. Rahman, "Day-ahead building-level load forecasts using deep learning vs. traditional time-series techniques," *Appl. Energy*, Vol. 236, pp. 1078-1088, Feb. 2019.
- [24] G. Amano, M. Marchesi, and A. Murru, "A hybrid genetic-neural architecture for stock indexes forecasting," *Information Sciences*, Vol. 170, No. 1, pp. 3-33, 2005.
- [25] A. M. Rather, A. Agarwal and V. Sastry, "Recurrent neural network and a hybrid model for prediction of stock returns," *Expert systems with applications*, Vol. 42, No. 6, pp. 3234-3241, 2015.
- [26] H. Wang, G. Wang, G. Li, J. Peng and Y. Liu, "Deep belief network based deterministic and probabilistic wind speed forecasting approach," *Applied Energy*, Vol. 182, pp. 80-93, 2016.
- [27] M. Khodayar, O. Kaynak, and M. E. Khodayar, "Rough deep neural architecture for short-term wind speed forecasting," *IEEE Transaction on Industrial Informatics*, Vol. 13, No. 6, pp. 2770-2779, 2017.
- [28] C. Voyant, G. Notton, S. Kalogirou, M.-L. Nivel, C. Paoli, F. Motte, and A. Foulloy, "Machine learning methods for solar radiation forecasting: A review," *Renewable Energy*, Vol. 105, pp. 569-581, 2017.
- classifiers," *Neural processing letters*, Vol 9, No. 3, pp. 293-300, 1999.
- [10] T. M. Mitchell, "Artificial neural networks," *Machine learning*, Vol. 45, pp. 81-127, 1997.
- [11] T. Lin, B. G. Home, P. Tino, and C. L. Giles, "Learning long-term dependencies in narx recurrent neural networks," *IEEE Transactions on Neural Networks*, Vol. 7, No. 6, pp. 1329-1338, 1996.
- [12] K.-i. Funahashi and Y. Nakamura, "Approximation of dynamical systems by continuous time recurrent neural networks," *Neural Networks*, Vol. 6, No. 6, pp. 801-806, 1993.
- [13] H. Shi, M. Xu, and R. Li, "Deep Learning for Household Load Forecasting—A Novel Pooling Deep RNN," *IEEE Trans. Smart Grid*, Vol. PP, No. 99, pp. 1–1, 2017.
- [14] A. Almalaq and G. Edwards, "A review of deep learning methods applied on load forecasting," in *Machine Learning and Applications (ICMLA)*, 2017 16th IEEE International Conference on. IEEE, 2017, pp. 511-516.
- [15] J. Kelly and W. Knottenbelt, "The uk-dale dataset, domestic appliance level electricity demand and whole-house demand from five uk homes," *Scientific data*, Vol. 2, p. 150007, 2015.
- [16] N. N. Karnik and J. M. Mendel, "Applications of type-2 fuzzy logic systems to forecasting of time-series," *Information Science*, Vol. 120, No. 1-4, pp. 89-111, 1999.
- [17] A. J. Conejo, M. A. Plazas, R. Espinola, and A. B. Molina, "Day-ahead electricity price forecasting using the wavelet transform and arima models," *IEEE Transaction on power systems*, Vol. 20, No. 5, pp. 1035-1042, 2005.
- [18] C. Bennet, R. A. Stewart, and J. Lu, "Autoregressive with exogenous variables and neural network short-term load forecast models for residential low voltage distribution networks," *Energies*, Vol. 7, No. 5, pp. 2938-2960, 2014
- [19] U. Kumar and V. Jain, "time series models (grey-markov, grey model with rolling mechanism and singular spectrum analysis) to forecast energy consumption in India," *Energy*, Vol. 35, No. 4, pp. 1453-1461, 2010.

- extraction via multiresolution analysis for short-term load forecasting. *IEEE Trans Power Syst*, Vol. 20, No. 1, 189–198, 2005.
- [35] M. J. Shensa, “The discrete wavelet transform: Wedding the à trous and Mallat algorithms,” *IEEE Trans. Signal Process.*, Vol. 40, No. 10, pp. 2464–2482, Oct. 1992.
- [36] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard, et al., “Tensorflow: A system for large-scale machine learning.” In *OSDI*, Vol. 16, pp. 265-283, 2016.
- [37] F. Chollet et al., “Keras: Deep learning library for theano and Tensorflow. (2015),” 2015.
- [38] T. J. Brailsford and R. W. Faff, “An evaluation of volatility forecasting techniques,” *Journal of Banking & Finance*, Vol. 20, No. 3, pp. 419-438, 1996.
- 582, 2017.
- [29] A. Alzahrani, P. Shamsi, C. Dagli, and M. Ferdowsi, “Solar irradiance forecasting using deep neural networks, *Procedia Computer Science*, Vol. 114, pp. 304-313, 2017.
- [30] Y. Wang, D. Gan, M. Sun, N. Zhang, Z. Lu, C. Kang, “Probabilistic individual load forecasting using pinball loss guided LSTM” *Appl Energy*, Vol 235 pp 10–20. 2019.
- [31] S. Ryu, J. Noh, and H. Kim, “Deep neural network based demand side short term load forecasting,” *Energies*, Vol. 10, No. 1, p. 3, 2016.
- [32] F. Keynia, “A new feature selection algorithm and composite neural network for electricity price forecasting”. *Eng. Appl. Artif. Intell.* 25, 1687-1697, 2012.
- [33] N. Amjady, "Short-Term Bus Load Forecasting of Power Systems by a New Hybrid Method," *IEEE Trans. Power Systems*, Vol. 22, No. 1, pp. 333- 341, Feb. 2007.
- [34] Rocha Reis AJ, Alves da Silva AP. Feature

¹Long Short Term Memory

²Auto Regressive Moving Average

³Support Vector Regression

⁴Recurrent Neural Networks

⁵Mean Absolute Error

⁶Root Mean Square Error

⁷Mean Absolute Percentage Error

⁸Deep Learning Neural Networks

⁹Back Propagation Neural Networks

¹⁰K- Nearest Neighbors

¹¹Extreme Machine Learning

¹²Kilowatt-Hour

¹³Fully Connected Layers