

A Hybrid Approach for Mid-Term Electricity Price Forecasting based on Support Vector Machine and Neural Networks

Navid Nazeri¹, Majid Moazzami^{1,2}, Ghazanfar Shahgholian^{1,2}

1- Smart Microgrid Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran.

2- Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran

Abstract:

In future smart grids, it's imperative to know the price of electricity market to guide the behavior of consumers and suppliers. This paper presents a hybrid approach for mid-term electricity price forecasting based on support vector machine and neural networks. In this method, at first, the price upper bound is considered. Then, the training set is divided into two parts including normal price and price spikes. Feature extraction applies on input data sets using stacked auto-encoders and a prediction model trained using each training set. Support Vector Machine (SVM) models with different kernel functions and a two layered feed-forward neural network were trained and tested with the proposed method. Simulation results using the proposed method show that this method has a significant effect on the speed of model training and improves forecasting accuracy.

Keywords: Autoencoder, Electricity Price Forecasting, Feed-Forward Neural Network, Support Vector Machine (SVM).

یک روش ترکیبی پیش‌بینی میان‌مدت قیمت برق در بازار تجدید ساختار شده با استفاده از ماشین بردار پشتیبان و شبکه‌های عصبی

نوید ناظری^۱، مجید معظمی^{۲*}، غضنفر شاهقلیان^۲

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

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

nazeri_navid@yahoo.com, m_moazzami@pel.iaun.ac.ir, shahgholian@iaun.ac.ir

چکیده: در شبکه‌های هوشمند آینده، اطلاع از قیمت بازار برق برای هدایت رفتار مصرف‌کنندگان و تولیدکنندگان ضروری است. در این مقاله روش ترکیبی پیش‌بینی میان‌مدت قیمت برق در بازار تجدید ساختار شده با استفاده از ماشین بردار پشتیبان و شبکه‌های عصبی ارائه شده است. در این روش ابتدا حد زیاد برای قیمت‌ها در نظر گرفته می‌شود؛ سپس مجموعه آموزش به دو قسمت جهش‌های قیمت و قیمت‌های معمولی تقسیم می‌شود. پس از آن، روی داده‌های ورودی عملیات استخراج ویژگی با استفاده از اتوانکدرهای به‌هم‌چسبیده انجام می‌گیرد و با استفاده از هر یک از مجموعه‌های آموزش، مدل تخمین آموزش داده می‌شود. مدل‌های بردار پشتیبان با توابع کرنل مختلف و شبکه عصبی دولایه پیشخور با استفاده از روش پیشنهادی، آموزش و آزموده می‌شوند. نتایج شبیه‌سازی با استفاده از روش پیشنهادی نشان می‌دهند این روش در افزایش سرعت آموزش مدل تأثیر چشم‌گیری دارد و موجب بهبود دقت پیش‌بینی می‌شود.

واژه‌های کلیدی: اتوانکدر، پیش‌بینی قیمت برق، شبکه عصبی پیشخور، ماشین بردار پشتیبان

۱- مقدمه^۱

با تجدیدساختار در سیستم‌های قدرت، پیش‌بینی قیمت برق برای مدیریت بازار برق بسیار مهم است و نقش کلیدی در عملیات در بازار برق و شبکه‌های هوشمند دارد [۱]. در بازار برق، قیمت برق مهم‌ترین سیگنال برای همه

شرکت‌کنندگان در بازار و قیمت تسویه بازار، پایه‌ای‌ترین مفهوم قیمت‌گذاری است [۲]. جهش‌های قیمت برق، ویژگی‌های بارزی‌اند که بر درستی پیش‌بینی تأثیرگذارند. در عمل وقتی میزان بار در سیستم به محدوده‌های ظرفیت تولید نزدیک می‌شود، پیش‌بینی دقیق جهش‌های قیمت پیچیده است؛ بنابراین مطالعه آماری جهش‌های قیمت و مطالعه توزیع احتمالی آنها در سطوح مختلف بار مفید خواهد بود [۲]. قیمت برق در بازار تجدید ساختار شده، بی‌ثباتی بیشتری نسبت به بار دارد؛ در نتیجه برای پیش‌بینی قیمت برق، مدل پیش‌بینی دقیق لازم است.

از جمله مطالعات انجام‌شده در زمینه پیش‌بینی با استفاده از ماشین‌های بردار پشتیبان می‌توان به بهینه‌سازی پارامترهای ماشین‌های بردار پشتیبان با استفاده از الگوریتم

^۱ تاریخ ارسال مقاله : ۱۳۹۷/۰۱/۱۱

تاریخ پذیرش مقاله : ۱۳۹۷/۰۵/۲۴

نام نویسنده مسئول : مجید معظمی

نشانی نویسنده مسئول : ایران - اصفهان - نجف‌آباد - بلوار دانشگاه - دانشگاه آزاد اسلامی - واحد نجف‌آباد - دانشکده مهندسی برق

دقیق ریسک در بازار تجدید ساختار شده استفاده شده است.

در مرجع [۱۲] از روش ترکیبی دو مرحله‌ای برای پیش‌بینی قیمت برق استفاده شده است. در مرحله نخست از روش یادگیری ماشین استفاده می‌شود تا در فواصل زمانی و با توجه به عدم قطعیت‌های موجود، قیمت برق پیش‌بینی شود. در مرحله دوم با استفاده از روش بیشترین درستی ممکن، تخمین میانگین خطا انجام می‌گیرد. در [۱۳] پیش‌بینی قیمت تسویه بازار در فواصل زمانی معتبر با بهره‌گیری از روش آموزش و فوق‌پذیر جامع و ترکیب روش‌های تخمین فواصل زمانی، شبکه‌های عصبی مصنوعی و فیلتر کالمن توسعه یافته صورت می‌گیرد. استفاده از روش NCFH^۷ مبتنی بر ماشین‌های بردار پشتیبان نیز به‌منظور پیش‌بینی قیمت برق در فواصل زمانی استفاده شده است [۱۴].

ترکیب روش یادگیری حداکثری ماشین و روش خودراه‌انداز نیز به‌منظور پیش‌بینی قیمت تسویه در بازار برق تجدید ساختار شده استفاده شده است [۱۵]. بسیاری از روش‌های مبتنی بر شبکه‌های عصبی مصنوعی برای فرمول‌بندی فواصل زمانی بین پیش‌بینی‌های معتبر توسعه داده شده‌اند که از این روش‌ها می‌توان روش دلتا، روش بیز، روش خودراه‌انداز و روش‌های میانگین واریانس را نام برد [۱۶-۲۱]. در بین روش‌های نام برده شده، استفاده از روش خودراه‌انداز ساده است و فواصل زمانی به‌دست‌آمده نیز از اعتبار کافی برخوردارند [۲۲]. آموزش حداکثری ماشین روشی برای آموزش شبکه عصبی مصنوعی تک‌لایه است که سرعت بسیار زیادی دارد. این روش قابلیت‌های بیشتری نسبت به شبکه‌های عصبی معمولی دارد و در مراجع [۲۴-۲۳] استفاده شده است. پیش‌بینی قیمت توان الکتریکی در بازارهای تجدید ساختار شده مختلف، در سراسر جهان در [۲۵-۳۰] ارائه شده است.

برای پیش‌بینی جهش‌های قیمت برق، چندین روش استفاده شده است [۳۱]. رگرسیون با مدل‌های جمع‌پذیر تعمیم‌یافته^۸ [۳۲] و روش کمترین کاهش و انتخاب عملگر Lasso [۳۳]، در پیش‌بینی‌های قیمت برق به‌تازگی استفاده شده‌اند. علاوه بر این، پیش‌بینی نقطه‌ای مقادیر و پیش‌بینی

توده ذرات برای پیش‌بینی بار در شبکه برق اشاره کرد [۳]. همچنین استفاده از چندین مدل ماشین بردار پشتیبان مبتنی بر روش کمترین مربعات خطا در^۱ [۴] گزارش شده است. مرجع [۵] مدلی برای پیش‌بینی قیمت برق ارائه داده است که حاصل ترکیب سری‌های زمانی فازی^۲ با الگوریتم بهینه‌سازی جستجوی هماهنگی سراسری (GHS^۳) و ماشین بردار پشتیبان براساس روش کمترین مربعات خطا است. در این روش در ابتدا مرکز خوشه‌بندی هر یک از خوشه‌ها محاسبه شده است؛ سپس مقادیر بهینه پارامترهای ماشین بردار پشتیبان با استفاده از الگوریتم جستجوی هماهنگی سراسری به دست آمده‌اند که مدل پیش‌بینی نهایی را تشکیل می‌دهند. مرجع [۶] روشی براساس جداسازی سری‌های زمانی قیمت برق و پیش‌بینی در مرحله بعد ارائه داده است. در این روش ابتدا داده‌های قیمت برق با استفاده از روش جداسازی Beveridge-Nelson^۴ به سه قسمت شامل داده‌های قطعی، داده‌های دوره‌ای و داده‌های تصادفی تقسیم می‌شوند؛ سپس با استفاده از الگوریتم بهینه‌سازی مگس میوه^۵ مقادیر بهینه پارامترهای ماشین بردار پشتیبان مبتنی بر روش کمترین مربعات خطا، محاسبه و برای هر یک از داده‌ها مدل پیش‌بینی، آموزش داده می‌شود. در مرجع [۷] از ترکیب دو شبکه عصبی عمیق، یعنی شبکه عصبی پیچیده و حافظه بلندمدت برای پیش‌بینی قیمت برق استفاده شده است. در [۸] عدم قطعیت مدل پیش‌بینی‌کننده در نظر گرفته شده است و از تکنیک بوت استرپینگ برای پیاده‌سازی عدم قطعیت استفاده شده است. روش مذکور از یادگیری تعمیم داده شده استفاده کرده است. این روش، مبتنی بر روش یادگیری ماشین شدید تعمیم یافته است که برای بهبود شبکه‌های عصبی استفاده می‌شود. مرجع [۹] از ترکیب روش‌هایی همچون تبدیل موجک، یادگیری ماشین شدید و بوت استرپ^۶، روشی برای پیش‌بینی بلادرنگ فواصل زمان و قیمت روز - پیش برق ارائه داده است. در مرجع [۱۰] شانزده نوع تبدیل برای تثبیت واریانس پیش‌بینی و کاهش شدت جهش قیمت بررسی شده است. نمونه‌ای از پیش‌بینی احتمالاتی میان‌مدت در مرجع [۱۱] ارائه شده است. در [۱۱] از رگرسیون چندکی برای تخمین

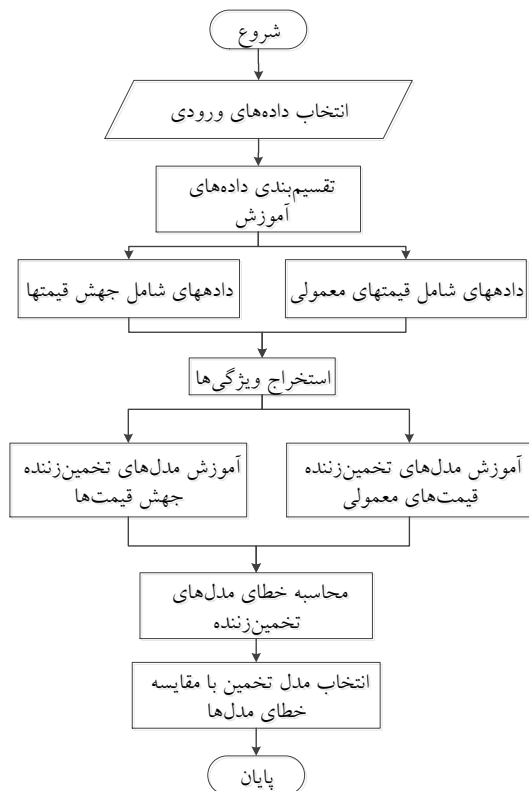
۲- روش پیشنهادی

مراحل روش پیشنهادی پیش‌بینی قیمت میان‌مدت شامل انتخاب داده‌های ورودی، پیش‌پردازش روی داده‌ها، آموزش مدل پیش‌بینی و محاسبه خطای پیش‌بینی‌اند.

در این مقاله از دو روش ترکیبی برای آموزش مدل اصلی پیش‌بینی قیمت و مقایسه خطای آنها با یکدیگر و دیگر روش‌ها برای پیش‌بینی قیمت برق استفاده شده است. مدل پیش‌بینی پیشنهادی در این مقاله در شکل (۱) نشان داده شده است.

در ابتدا داده‌های آموزش و آزمایش برای انجام روش پیشنهادی انتخاب می‌شود. سپس داده‌ها به دو قسمت داده‌های مربوط به قیمت‌های معمولی و جهش‌ها تقسیم می‌شوند. پس از آن، روی هر یک از مجموعه‌ها استخراج ویژگی‌ها انجام می‌شود و سپس با استفاده از هر یک از مجموعه‌ها مدل تخمین‌زننده آموزش داده می‌شود.

در مرحله بعد خطای پیش‌بینی‌ها، اندازه‌گیری و با مقایسه خطاها مدل پیش‌بینی انتخاب می‌شود.



شکل (۱): فلوچارت روش پیشنهادی

احتمالاتی در [۳۴] انجام شده است. بیشتر مدل‌های سری‌های زمانی با قابلیت پیش‌بینی قیمت برق از طریق رابطه خطی بین ورودی‌ها کار می‌کنند. در مطالعات اخیر [۳۵-۳۶] از مدل‌های توسعه داده آماری استفاده شده است که توانایی شناسایی ویژگی‌های غیرخطی در داده‌ها را دارند. روش‌های داده‌محور با استفاده از روابط غیرخطی بین ورودی‌ها به بهبود درستی پیش‌بینی کمک می‌کنند. استفاده از ماشین‌های بردار پشتیبان در پیش‌بینی قیمت برق در [۳۹-۳۷] آمده است. مطالعه‌ای که در [۴۰] انجام شده است، روش‌های مختلف پیش‌بینی قیمت برق را مرور کرده و به این نتیجه رسیده است که روش‌های داده‌محور به خصوص روش‌های مبتنی بر شبکه‌های عصبی نتایج بسیار خوبی ارائه می‌دهند.

در این مقاله روش دقیق پیش‌بینی قیمت میان‌مدت برق با استفاده از روش یادگیری ماشین، اتوانکدرهای پراکنده متصل به هم و شبکه‌های عصبی ارائه شده است. در روش پیشنهادی پیش‌پردازش داده‌ها بدون نظارت است. با پیش‌پردازش ورودی‌ها، استخراج ویژگی‌ها با استفاده از اتوانکدرهای پراکنده متصل به هم انجام شده که حاصل آن انتخاب ویژگی‌های بارز در ورودی‌ها و حذف ویژگی‌های کم‌اثر است. اتوانکدرهای متصل به یکدیگر به صورت متوالی ورودی داده‌شده را کدگذاری و سپس داده‌های لایه مخفی را کدگذاری می‌کنند. این کار برای کپی کردن ورودی در خروجی است؛ به طوری که فقط داده‌های با ویژگی‌های بارزتر باقی می‌مانند. این روند باعث کاهش ابعاد ورودی‌ها و افزایش سرعت یادگیری روش پیشنهادی می‌شود. پس از آن جهش‌های قیمت و ورودی‌های مربوط به آنها از مجموعه داده‌ها جدا می‌شوند و مجموعه آموزش جداگانه را تشکیل می‌دهند و با استفاده از هر یک از مجموعه‌ها مدل پیش‌بینی ساخته می‌شود. به این ترتیب نتایج حاصل از ترکیب پیش‌بینی دو مدل ایجاد می‌شود که موجب بهبود دقت پیش‌بینی نهایی خواهد شد. برای یافتن بهترین تابع کرنل برای ساختن مدل‌های پیش‌بینی، مدل‌ها با استفاده از چندین کرنل آموزش داده می‌شوند و تابع کرنلی انتخاب می‌شود که بهترین پاسخ را ارائه داده است.

۲-۱- انتخاب داده‌های آموزش

مجموعه داده‌های آموزش در پیش‌بینی قیمت برق اعم از کوتاه‌مدت، میان‌مدت یا بلندمدت، داده‌های پیشین است. داده‌های استفاده‌شده برای آموزش مدل‌های پیش‌بینی‌کننده در شکل (۲) نمایش داده شده‌اند.

اطلاعات پایگاه داده برای شبیه‌سازی روش پیشنهادی مربوط به سال ۲۰۰۵ و ۲۰۰۶ بازار استرالیا است. داده‌های روز یکم ژانویه ۲۰۰۵ تا سی و یکم دسامبر ۲۰۰۵ برای آموزش مدل‌ها و داده‌های مربوط به ماه ژانویه سال ۲۰۰۶ برای آزمایش مدل‌ها استفاده شده‌اند. در آموزش مدل‌های نظارت‌شده هدف یا به عبارتی خروجی مطلوب، قیمت برق خواهد بود.



شکل (۲): ورودی‌های مدل آموزش

۲-۲- پیش‌پردازش روی داده‌ها

۲-۲-۱- کنترل جهش‌های قیمت

برای کنترل جهش‌های قیمت ابتدا حد بیشتری برای قیمت برق در نظر گرفته می‌شود. قیمت‌های بیشتر از حد بالا از مجموعه آموزش حذف می‌شوند و مدل پیش‌بینی اصلی بدون جهش‌های قیمت آموزش داده می‌شود.

$$S = \begin{cases} \text{if } P_i \leq UL & S_{primary} = P \\ \text{if } P_i > UL & S_{secondary} = P, i = 1: \text{length}(s) \end{cases} \quad (1)$$

S کل مجموعه آموزش است. با تقسیم‌بندی مجموعه آموزش به قیمت‌های معمولی و جهش‌ها دو زیرمجموعه آموزش به دست می‌آید و جهش‌های قیمت و ورودی‌های مربوط به آنها که از مجموعه آموزش جدا شده است، مجموعه آموزش دیگری را می‌سازد. سپس از این مجموعه

آموزش جدید، برای آموزش مدلی برای تخمین جهش‌های قیمت استفاده می‌شود.

در مرحله تخمین آنالیز، داده‌های ورودی‌ها به دو مدل تخمین‌زننده قیمت‌های معمولی و جهش‌ها داده می‌شوند و مجموعه پیش‌بینی‌ها براساس تاریخ داده‌ها مرتب می‌شوند.

۲-۲-۲- پیش‌پردازش روی داده‌های ورودی

در مرحله آموزش هر دو مدل تخمین‌زننده قیمت، در مرحله انتخاب ویژگی‌ها از دو اتوانکدر پراکنده برای یادگیری ویژگی‌های ورودی استفاده شده است. شبکه عصبی اتوانکدر، الگوریتم آموزشی بدون نظارت است که با استفاده از الگوریتم پس‌انتشار خطا آموزش می‌بیند تا ورودی‌هایش را در خروجی کپی کند. درون آن لایه مخفی h وجود دارد. این لایه مخفی کدی را توصیف می‌کند که برای نمایش ورودی‌ها استفاده می‌شود. اتوانکدر از یک تابع کدکننده و یک مبدل کد تشکیل شده است [۴۱].

$$h = f(x) \quad (2)$$

$$r = g(h) \quad (3)$$

$$g(f(x)) = x \quad (4)$$

یکی از راه‌های به دست آوردن ویژگی‌های مفید از اتوانکدر، محدودکردن h به داشتن ابعاد کوچک‌تر از x است. اتوانکدری که ابعاد کد آن کوچک‌تر از ابعاد ورودی آن باشد را ناکامل گویند. یادگیری ناکامل باعث می‌شود اتوانکدر برجسته‌ترین ویژگی‌های داده‌های آموزشی را انتخاب کند. روند آموزش را می‌توان به سادگی با مینیمم کردن تابع زیان زیر نشان داد:

$$L(x, g(f(x))) \quad (5)$$

L تابع زیان که معمولاً تابعی مانند میانگین مربعات خطا است، $g(f(x))$ را برای ناهمسانی با x جریمه می‌کند. در صورتی که ظرفیت مناسب برای اتوانکدر انتخاب شود ویژگی‌های بارز داده‌های آموزش را استخراج می‌کند. اتوانکدر پراکنده، اتوانکدری است که علاوه بر خطای بازسازی، یک عامل جریمه پراکنده در لایه کد h دارد [۳۷].


$$L(x, g(f(x))) + \Omega(h) \quad (6)$$

که:

$$j(W, b) = \left[\frac{1}{m} \sum_{i=1}^m j(W, b; x^{(i)}, y^{(i)}) \right] + \frac{\lambda}{2} \sum_{l=1}^{n-1} \sum_{j=1}^{s_l+1} (W_{jl}^{(l)})^2 = \left[\frac{1}{m} \sum_{i=1}^m \left(\frac{1}{2} \square h_{W,b}(x^{(i)}) - y^{(i)} \right)^2 \right] + \frac{\lambda}{2} \sum_{l=1}^{n-1} \sum_{j=1}^{s_l+1} (W_{jl}^{(l)})^2 \quad (13)$$

در روابط فوق نخستین عبارت در تعریف $j(W, b)$ میانگین مجموع مربعات خطا است. عبارت دوم عبارت تنظیم‌کننده است که تمایل به کاهش شدت وزن‌ها دارد و به جلوگیری از overfit کمک می‌کند. پارامتر تنظیم‌کننده λ رابطه بین دو عبارت نخست را کنترل می‌کند. $J(W, b; x^{(i)}, y^{(i)})$ مربعات خطا نسبت به یک نمونه است. $\hat{\rho}_j$ به وزن و بایاس وابسته است؛ زیرا $\hat{\rho}_j$ میانگین فعالیت نورون زدر لایه مخفی است و فعالیت نورون وابسته به وزن و بایاس است.

می‌توان از اتوانکدهای به هم چسبیده برای استخراج ویژگی‌ها استفاده کرد. این اتوانکدها ویژگی‌های ورودی‌ها را به صورت بدون نظارت یاد می‌گیرند. درحقیقت روش استفاده شده در این مقاله ترکیب آموزش بدون نظارت و آموزش نظارت شده به منظور کاهش خطای پیش‌بینی است. استفاده از این روش برای استخراج ویژگی‌ها علاوه بر این که باعث انتخاب ویژگی‌های مؤثرتر برای آموزش مدل و حذف ویژگی‌های کم‌اثر می‌شود، موجب کاهش ابعاد ورودی‌ها و افزایش سرعت یادگیری مدل اصلی می‌شود. ساختار این اتوانکدها در شکل (۳) نشان داده شده است.



شکل (۳): ساختار اتوانکدهای پراکنده به هم چسبیده

$g(h)$ ، خروجی مدل کد و معمولاً $h(f(x))$ خروجی کدکننده‌اند. اتوانکدهای پراکنده معمولاً برای یادگیری ویژگی‌ها برای انجام کار دیگری مانند دسته‌بندی استفاده می‌شوند. اتوانکداری که برای پراکنده‌بودن تنظیم شده است باید به ویژگی‌های منحصربه‌فرد آماری مجموعه داده‌ها پاسخ دهد. به این ترتیب آموزش دیدن برای کپی کردن با عامل جریمه پراکنده‌گی موجب ساخت مدلی می‌شود که ویژگی‌های مفید را به عنوان نتیجه جانبی یاد می‌گیرد.

می‌توان عامل جریمه $\Omega(h)$ را مانند رابطه تنظیم‌کننده در نظر گرفت که به شبکه پیشخور اضافه شده و وظیفه اصلی آن کپی کردن ورودی در خروجی است که احتمالاً برخی وظایف نظارت شده را انجام می‌دهد که به این ویژگی‌های پراکنده بستگی دارد. میانگین فعالیت نورون لایه مخفی ρ در مجموعه آموزش از رابطه زیر به دست می‌آید:

$$\hat{\rho}_j = \frac{1}{m} \sum_{i=1}^m [a_j^{(2)}(x^{(i)})] \quad (7)$$

$$\hat{\rho}_j = \rho \quad (8)$$

ρ پارامتر پراکنده‌گی است و معمولاً مقدار آن کوچک و نزدیک به صفر است. برای انجام شدن این قید، فعال‌سازی نورون‌های لایه مخفی باید در نزدیکی صفر باشد. برای دستیابی به آن، عامل جریمه به تابع هدف بهینه‌سازی اضافه می‌شود. عامل جریمه به شکل زیر در تابع هدف قرار می‌گیرد:

$$\sum_{j=1}^{s^2} \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (9)$$

s^2 تعداد نورون‌های لایه مخفی است. عبارت جریمه براساس واگرایی KL^9 است.

$$\sum_{j=1}^{s^2} KL(\rho \square \hat{\rho}_j) \quad (10)$$

$$KL(\rho \square \hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (11)$$

مینیم کردن این عبارت جریمه باعث نزدیک شدن $\hat{\rho}_j$ به ρ می‌شود.

تابع هدف کل برابر است با:

$$j_{sparse}(W, b) = j(W, b) + \beta \sum_{j=1}^{s^2} KL(\rho \square \hat{\rho}_j) \quad (12)$$

۲-۳- آموزش مدل‌های پیش‌بینی

$$t_n \leq y(x_n) + \varepsilon + \xi_n \quad (19)$$

$$t_n \leq y(x_n) - \varepsilon - \xi_n \quad (20)$$

۲-۳-۱- مدل رگرسیون بردار پشتیبان^{۱۱}

رابطه زیر را در نظر بگیرید [۴۲]:

$$y(x) = w^T \phi(x) + b \quad (14)$$

$\phi(x)$ تبدیل ثابت فضای ویژگی‌ها و b بایاس است. می‌توان از ماشین‌های بردار پشتیبان با حفظ ویژگی پراکندگی، برای حل مسائل رگرسیون استفاده کرد.

در رگرسیون خطی ساده تابع خطای تنظیم‌شده زیر مینیمم می‌شود:

$$\frac{1}{2} \sum_{n=1}^N \{y_n - t_n\}^2 + \frac{\lambda}{2} \|w\|^2 \quad (15)$$

برای به دست آوردن حل پراکنده، تابع خطای درجه دو، تابع خطای غیرحساس به پارامتر ε^1 است. وقتی $\varepsilon > 0$ باشد، اگر قدر مطلق تفاضل پاسخ پیش‌بینی‌شده $y(x)$ و پاسخ مطلوب t از ε کوچک‌تر باشد، خروجی تابع خطا برابر با صفر خواهد بود. یک مثال ساده تابع خطای غیرحساس به پارامتر ε در رابطه زیر آمده است.

$$E_\varepsilon(y(x)-t) = \begin{cases} 0 & \text{if } |y(x)-t| < \varepsilon \\ |y(x)-t| - \varepsilon & \text{otherwise} \end{cases} \quad (16)$$

در نتیجه تابع خطای تنظیم‌شده زیر باید مینیمم شود:


$$C \sum_{n=1}^N E_\varepsilon(y(x_n) - t_n) + \frac{1}{2} \|w\|^2 \quad (17)$$

$y(x)$ از رابطه (۱۴) به دست می‌آید و C معکوس پارامتر تنظیم‌کننده است. می‌توان مسئله بهینه‌سازی را با استفاده از متغیرهای کمکی بازنویسی کرد. برای هر نقطه از داده‌ها x_n دو متغیر کمکی $\xi_n \geq 0$ و $\hat{\xi}_n \geq 0$ نیاز است. $\xi_n > 0$ مربوط به نقاطی است که $t_n > y(x_n) + \varepsilon$ و $\hat{\xi}_n > 0$ مربوط به نقاطی است که $t_n > y(x_n) - \varepsilon$ است و در شکل (۴) نشان داده شده‌اند.

شرط لازم برای آنکه نقطه خروجی مطلوب در منطقه ε قرار گیرد برابر است با:

$$y_n - \varepsilon \leq t_n \leq y_n + \varepsilon, \quad y_n = y(x_n) \quad (18)$$

معرفی متغیرهای کمکی اجازه می‌دهد تا نقاط خارج از منطقه ε متغیرهای کمکی غیرصفر با شرایط زیر تولید کنند:



شکل (۴): نمایش رگرسیون بردار پشتیبان و منحنی رگرسیون با منطقه غیرحساس به پارامتر ε و نمونه‌هایی از متغیرهای کمکی ξ و $\hat{\xi}$ [۴۲]

تابع خطای رگرسیون بردار پشتیبان به شکل زیر نوشته می‌شود [۳۸]:

$$C \sum_{n=1}^N (\xi_n + \hat{\xi}_n) + \frac{1}{2} \|w\|^2 \quad (21)$$

که باید نسبت به قیود (۱۹) و (۲۰)، $\xi_n \geq 0$ و $\hat{\xi}_n \geq 0$ مینیمم شود. این کار با انتخاب چهار ضریب لاگرانژ برای هر یک از چهار قیود و استفاده از بهینه‌سازی لاگرانژ ممکن می‌شود. ضرایب لاگرانژ $a_n \geq 0$ ، $\hat{a}_n \geq 0$ ، $\mu_n \geq 0$ و $\hat{\mu}_n \geq 0$ هستند و تابع لاگرانژ به صورت زیر است:

$$L = C \sum_{n=1}^N (\xi_n + \hat{\xi}_n) + \frac{1}{2} \|w\|^2 - \sum_{n=1}^N (\mu_n \xi_n + \hat{\mu}_n \hat{\xi}_n) - \sum_{n=1}^N a_n (\varepsilon + \xi_n + y_n - t_n) - \sum_{n=1}^N \hat{a}_n (\varepsilon + \hat{\xi}_n - y_n + t_n) \quad (22)$$

با جای‌گذاری رابطه (۱۴) در تابع لاگرانژ فوق و مشتق‌گیری از آن نسبت به w ، b ، ξ_n و $\hat{\xi}_n$ و مساوی صفر قراردادن مشتق‌ها روابط زیر به دست می‌آید:

$$\frac{\partial L}{\partial w} = 0 \Rightarrow w = \sum_{n=1}^N (a_n - \hat{a}_n) \phi(x_n) \quad (23)$$

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{n=1}^N (a_n - \hat{a}_n) = 0 \quad (24)$$

$$\frac{\partial L}{\partial \xi_n} = 0 \Rightarrow a_n + \mu_n = C \quad (25)$$

در داده‌ها است که روی کران پایین منطقه \mathcal{E} یا پایین آن قرار دارند. علاوه بر این، قیود $\varepsilon + \xi_n + y_n - t_n = 0$ و $\varepsilon + \hat{\xi}_n - y_n + t_n = 0$ با یکدیگر در تضادند. بردارهای پشتیبان آن نقاطی در مجموعه داده‌ها هستند که در پیش‌بینی داده‌های جدید با استفاده از رابطه (۳۴) مشارکت می‌کنند، یا به عبارتی، نقاطی در داده‌ها که برای آنها $a_n \neq 0$ یا $\hat{a}_n \neq 0$ باشد. این نقاط، نقاطی اند که روی کران‌های منطقه \mathcal{E} یا خارج از آن قرار دارند. برای تمامی نقاط داخل منطقه \mathcal{E} ، $a_n = \hat{a}_n = 0$ است. برای حل این مسئله راه‌حل پراکنده وجود دارد و تنها قسمتی که باید در رابطه (۳۴) ارزیابی شود، قسمتی است که بردارهای پشتیبان را شامل می‌شود. با در نظر گرفتن نقاطی که برای آنها $0 \leq a_n \leq C$ باشد و با توجه به رابطه (۳۷)، ξ_n برابر صفر داشته باشند، با توجه به رابطه (۳۵)، عبارت $\varepsilon + y_n - t_n = 0$ برایشان برقرار باشد، در این صورت می‌توان رابطه بایاس را پیدا کرد. با استفاده از رابطه (۲۳) می‌توان نوشت:

$$b = t_n - \varepsilon - w^T \phi(x_n) = t_n - \varepsilon - \sum_{m=1}^N (a_m - \hat{a}_m) k(x_n, x_m) \quad (39)$$

با در نظر گرفتن نقاطی که برای آنها $0 \leq \hat{a}_n \leq C$ باشد نتیجه مشابهی به دست می‌آید. بهتر است از تمام تخمین‌هایی از b مانند رابطه (۳۹) میانگین گرفته شود. مانند دسته‌بندی، برای رگرسیون نیز روش فرمول‌بندی دیگر وجود دارد. معمولاً به جای ثابت کردن عرض ناحیه غیرحساس، پارامتری مانند ν ثابت می‌شود که نقاط خارج از منطقه \mathcal{E} را مقید می‌کند. این روند شامل ماکزیم کردن مقید تابع لاگرانژ زیر است [۴۲].

$$\tilde{L}(a, \hat{a}) = -\frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N (a_n - \hat{a}_n)(a_m - \hat{a}_m) k(x_n, x_m) + \sum_{n=1}^N (a_n - \hat{a}_n) t_n \quad (40)$$

$$0 \leq a_n \leq C/N \quad (41)$$

$$0 \leq \hat{a}_n \leq C/N \quad (42)$$

$$\sum_{n=1}^N (a_n - \hat{a}_n) = 0 \quad (43)$$

$$\frac{\partial L}{\partial \xi} = 0 \Rightarrow \hat{a}_n + \hat{\mu}_n = C \quad (26)$$

با استفاده از این نتایج برای حذف متغیرهای مربوطه در تابع لاگرانژ، مسئله فرمول‌بندی دویخشی با ماکزیم کردن تابع لاگرانژ زیر نسبت به $\{a_n\}$ و $\{\hat{a}_n\}$ و استفاده از تعریف تابع کرنل حاصل می‌شود:

$$\tilde{L}(a, \hat{a}) = -\frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N (a_n - \hat{a}_n)(a_m - \hat{a}_m) k(x_n, x_m) - \varepsilon \sum_{n=1}^N (a_n - \hat{a}_n) + \sum_{n=1}^N (a_n - \hat{a}_n) t_n \quad (27)$$

این مسئله ماکزیم کردن مقید است و برای یافتن قیود، روابط (۲۴)–(۲۶) و قیود زیر لازم است:

$$a_n \geq 0, \hat{a}_n \geq 0 \quad (28)$$

$$a_n \leq C, \hat{a}_n \leq C \quad (29)$$

$$0 \leq a_n \leq C \quad (30)$$

$$0 \leq \hat{a}_n \leq C \quad (31)$$

$$a_n \geq 0, \hat{a}_n \geq 0 \quad (32)$$

$$\mu_n \geq 0, \hat{\mu}_n \geq 0 \quad (33)$$

با جای‌گذاری رابطه (۲۳) در رابطه (۱۴)، پیش‌بینی برای داده‌های جدید با استفاده از رابطه زیر ممکن می‌شود:

$$y(x) = \sum_{n=1}^N (a_n - \hat{a}_n) k(x, x_n) + b \quad (34)$$

شرایط KKT متناسب با این مسئله برابر است با [۳۸]:

$$a_n (\varepsilon + \xi_n + y_n - t_n) = 0 \quad (35)$$

$$\hat{a}_n (\varepsilon + \hat{\xi}_n - y_n + t_n) = 0 \quad (36)$$

$$(C - a_n) \xi_n = 0 \quad (37)$$

$$(C - \hat{a}_n) \hat{\xi}_n = 0 \quad (38)$$

از روابط فوق نتایج مفیدی به دست می‌آید. نخستین نکته اینکه ضریب a_n فقط وقتی غیرصفر است که $\varepsilon + \xi_n + y_n - t_n = 0$ که روی کران بالای منطقه \mathcal{E} یا بالای آن قرار دارند.

به‌طور مشابه ضریب \hat{a}_n فقط وقتی $\varepsilon + \hat{\xi}_n - y_n + t_n = 0$ باشد، غیرصفر است و شامل نقاطی

یک روش ترکیبی پیش‌بینی میان‌مدت قیمت برق در بازار تجدید ساختار شده با استفاده از ...

(۴) میانگین قدرمطلق درصد خطا:

فرض کنید y_n مقدار پیش‌بینی شده و t_n مقدار مطلوب قیمت برق باشد، مقدار میانگین t_n به صورت زیر تعریف می‌شود:

$$\bar{t} = \frac{1}{N} \sum_{n=1}^N t_n \quad (49)$$

درصد خطا به صورت زیر تعریف می‌شود:

$$PE = \frac{y_n - t_n}{\bar{t}} \times 100 \quad (50)$$

و درصد مطلق خطا برابر است با:

$$APE = |PE| \quad (51)$$

بنابراین میانگین قدرمطلق درصد خطا به صورت زیر است [۴۳]:

$$MAPE = \frac{1}{N} \sum_{i=1}^N APE_i \quad (52)$$

(۵) خطای R^2 :

فرض کنید \hat{Y} برداری شامل n پیش‌بینی باشد و Y برداری شامل n مقدار مطلوب متناسب با پیش‌بینی‌های \hat{Y} باشد، مجموع مربعات کل و باقیمانده مجموع مربعات برابر است با:

$$SS_{tot} = \sum_i (Y_i - \bar{Y})^2 \quad (53)$$

$$SS_{res} = \sum_i (Y_i - \hat{Y}_i)^2 \quad (54)$$

در نتیجه خطای مربعات R به صورت زیر تعریف می‌شود:

$$R^2 \equiv 1 - \frac{SS_{res}}{SS_{tot}} \quad (55)$$

فلوچارت روش پیشنهادی در مرحله پیش‌بینی در شکل (۵) نمایش داده شده است.

$$\sum_{n=1}^N (a_n - \hat{a}_n) \leq vC \quad (44)$$

می‌توان نشان داد حداکثر vN نقطه در داده‌ها بیرون از ناحیه غیرحساس قرار می‌گیرد؛ در حالی که حداقل vN نقطه در داده‌ها بردارهای پشتیبان‌اند که می‌توانند درون ناحیه غیرحساس یا بیرون آن قرار داشته باشند.

۲-۴- محاسبه خطای پیش‌بینی

برای ارزیابی دقت پیش‌بینی باید خطای پیش‌بینی محاسبه شود. شاخص‌های استاندارد محاسبه خطا شامل میانگین مربعات خطا، جذر میانگین مربعات خطا، میانگین خطای مطلق، میانگین قدر مطلق درصد خطا و خطای R^2 است.

(۱) میانگین مربعات خطا

اگر \hat{Y} برداری شامل n پیش‌بینی باشد و Y برداری شامل n مقدار مطلوب متناسب با پیش‌بینی‌های \hat{Y} باشد، میانگین مربعات خطا برابر است با:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (45)$$

(۲) جذر میانگین مربعات خطا

اگر \hat{Y} برداری شامل n پیش‌بینی باشد و Y برداری شامل n مقدار مطلوب متناسب با پیش‌بینی‌های \hat{Y} باشد، جذر میانگین مربعات خطا برابر است با:

$$RMSE = \sqrt{MSE(\hat{Y})} = \sqrt{E((\hat{Y} - Y)^2)} \quad (46)$$

در نتیجه جذر میانگین مربعات خطا برابر است با:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{n}} \quad (47)$$

(۳) میانگین خطای مطلق

اگر \hat{Y} برداری شامل n پیش‌بینی باشد و Y برداری شامل n مقدار مطلوب متناسب با پیش‌بینی‌های \hat{Y} باشد، میانگین خطای مطلق برابر است با:

$$MAE = \frac{\sum_{i=1}^n |\hat{Y}_i - Y_i|}{n} \quad (48)$$

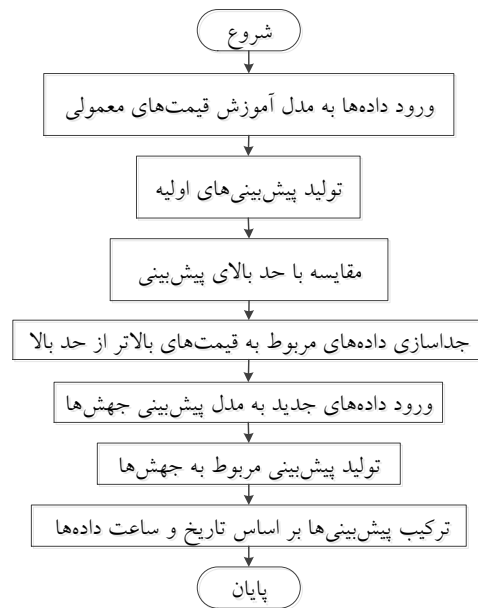
در روش ارائه شده در این مقاله، استخراج ویژگی‌ها که حاصل آن انتخاب ویژگی‌های بارز در ورودی‌ها و حذف ویژگی‌های کم‌اثر است، موجب کاهش ابعاد ورودی‌ها می‌شود. این کار همچنین موجب افزایش سرعت یادگیری مدل‌های پیش‌بینی می‌شود. برای استخراج ویژگی‌ها و کاهش ابعاد ورودی‌ها از اتوانکدرهای پراکنده متصل به هم استفاده شده است. یکی از راه‌های به دست آوردن ویژگی‌های مفید از اتوانکدر، محدود کردن آن به داشتن ابعاد کد کوچک‌تر است. اتوانکدرهای استفاده شده در این مقاله اتوانکدرهای ناکامل، پراکنده و تنظیم شده هستند. ورودی اتوانکدر اول ستون‌های ماتریس شامل ورودی‌های نامبرده شده است و ورودی اتوانکدر دوم ویژگی‌های استخراج شده از ماتریس ورودی اتوانکدر اول است. مشخصات آموزش اتوانکدرهای به هم چسبیده در جدول (۱) نمایش داده شده‌اند.

جدول (۱): مشخصات اتوانکدرهای استفاده شده در شبیه‌سازی

شماره اتوانکدر	۱	۲
تعداد نورون‌های لایه مخفی	۱۴	۱۰
تنظیم‌کننده وزن L_2	۰/۰۰۱	۰/۰۰۱
تنظیم‌کننده پراکندگی	۴	۴
اندازه پراکندگی	۰/۰۵	۰/۰۵
تابع انتقال مبدل کد	خطی	خطی
تغییر ابعاد داده‌ها	ندارد	دارد

۳-۲- آموزش مدل‌های پیش‌بینی

مدل‌های پیش‌بینی‌کننده براساس ماشین‌های بردار پشتیبان، با استفاده از توابع کرنل خطی، چندجمله‌ای و گوسی آموزش داده شده‌اند. نتایج شبیه‌سازی با استفاده از روش پیشنهادی در جدول (۲) و نتایج مشابه با استفاده از بردارهای پشتیبان (بدون پیش‌پردازش، تفکیک داده‌های آموزش و پردازش روی خروجی مدل‌ها) در جدول (۳) نشان داده شده‌اند.




شکل (۵): فلوجارت روش پیشنهادی در پیش‌بینی

۳-۳- نتایج شبیه‌سازی

۳-۳-۱- پیش‌پردازش


همان‌گونه که در بخش ۲-۱- اشاره شد، اطلاعات پایگاه داده برای شبیه‌سازی روش پیشنهادی مربوط به سال ۲۰۰۵ و ۲۰۰۶ بازار استرالیا است [۴۵]. در بخش‌های قبل اشاره شد که داده‌های روز یکم ژانویه ۲۰۰۵ تا سی و یکم دسامبر ۲۰۰۵ برای آموزش مدل‌ها و داده‌های مربوط به ماه ژانویه سال ۲۰۰۶ برای آزمایش مدل‌ها استفاده شده‌اند. در شبیه‌سازی‌های انجام شده در این مقاله، حد زیاد قیمت در $150 \$/MWh$ در نظر گرفته شده است. به این ترتیب قیمت‌های بیشتر از آن و ورودی‌های آنها مجموعه آموزش ثانویه خواهند ساخت. نتایج جداسازی جهش‌های قیمت در شکل (۶) نمایش داده شده‌اند.




شکل (۶): جداسازی مجموعه‌های آموزش

یک روش ترکیبی پیش‌بینی میان‌مدت قیمت برق در بازار تجدید ساختار شده با استفاده از ...

از متغیرهای مستقل و با ثابت‌بودن دیگر متغیرهای مستقل تغییر می‌کند.



شکل (۷): پاسخ مدل آموزش دیده با استفاده از تابع کرنل چندجمله‌ای به داده‌های آموزش



شکل (۸): نمودار رگرسیون مدل آموزش دیده با تابع کرنل چندجمله‌ای

بیشترین کاربرد تحلیل رگرسیون تخمین امید ریاضی شرطی متغیر وابسته از متغیرهای مستقل معین است که معادل مقدار متوسط متغیر وابسته است، وقتی که متغیرهای مستقل ثابت‌اند. کمترین کاربرد آن تمرکز بر چندک یا پارامتر مکانی توزیع شرطی متغیر وابسته از متغیر مستقل معین است. در همه موارد، هدف، تخمین یک تابع از متغیرهای مستقل است که تابع رگرسیون نامیده شده است. در تحلیل رگرسیون، تعیین پراکندگی متغیر وابسته اطراف تابع رگرسیون شایان توجه است که با توزیع احتمال توضیح داده می‌شود. در نمودارهای رگرسیون در این مقاله، متغیر مستقل مقادیر واقعی قیمت برق و متغیر وابسته قیمت‌های پیش‌بینی شده‌اند. هرچه تعداد بیشتری از دایره‌های مشکی روی خط آبی رنگ قرار گیرند، پیش‌بینی بهتری انجام شده است.

با مقایسه نتایج جدول (۲) با جدول (۳) نتیجه می‌گیریم لقب ۵۶۷ روش پیشنهادی موجب کاهش میانگین قدرمطلق

جدول (۲): نتایج آموزش مدل‌های پیش‌بینی با استفاده از روش

پیشنهادی

مدل	کرنل خطی	کرنل گوسی متوسط ^{۱۲}	کرنل گوسی سخت ^{۱۳}	کرنل گوسی ^{۱۴}	کرنل چند جمله‌ای ^{۱۵}
MSE	۴۶/۴	۲۲/۴۳	۴۲/۶۲	۶۹/۸۱	۲۰/۸۷
RMSE	۶/۸۱	۴/۷۳	۶/۵۲	۸/۳۵	۴/۵۶
R-squared	۰/۸۴	۰/۸۲	۰/۸۸	۰/۷۸	۰/۸۰
MAE (\$/MWh)	۴/۴۳	۳/۱۸	۳/۹۷	۳/۳۰	۳/۴۴
زمان آموزش (ثانیه)	۸۵۵/۰۴	۵۲۵/۶۰	۳۴۲/۴۴	۱۶۲/۶۶	۱۹۶/۸۶


جدول (۳): نتایج آموزش مدل‌های پیش‌بینی با استفاده از

ماشین‌های بردار پشتیبان بدون استفاده از روش پیشنهادی


مدل	کرنل خطی	کرنل گوسی متوسط	کرنل گوسی سخت	کرنل گوسی چندجمله‌ای
MSE	۶۹/۲۹	۲۴/۷۳	۵۵/۹۱	۲۱/۷۱
RMSE	۸/۳۲	۴/۹۷	۷/۴۸	۴/۶۵
R-squared	۰/۸۷	۰/۹۵	۰/۸۹	۰/۸۴
MAE (\$/MWh)	۶/۳۴	۶/۱۶	۵/۶۷	۵/۵۴
زمان آموزش (ثانیه)	۸۴۲/۳۵	۵۶۳/۵۹	۳۸۲	۱۳۹۹

با مقایسه نتایج جدول (۲) و جدول (۳) درمی‌یابیم بهترین تابع کرنل برای آموزش مدل تخمین قیمت برق با استفاده از ماشین‌های بردار پشتیبان، کرنل چندجمله‌ای است. علاوه بر این، این مدل زمان آموزش نسبتاً مناسبی دارد. نمودار مدل پیش‌بینی با کرنل چندجمله‌ای به مجموعه داده‌های آموزش در شکل (۷) و نمودار رگرسیون آن در شکل (۸) نمایش داده شده است.

در مدل‌های آماری، تحلیل رگرسیون، فرآیند آماری برای تخمین روابط بین متغیرها است. این روش شامل تکنیک‌های زیادی برای مدل‌سازی و تحلیل متغیرهای خاص و منحصربه‌فرد، با تمرکز بر رابطه بین متغیر وابسته و یک یا چند متغیر مستقل است. تحلیل رگرسیون در فهم این کمک می‌کند که چگونه مقدار متغیر وابسته با تغییر هر کدام

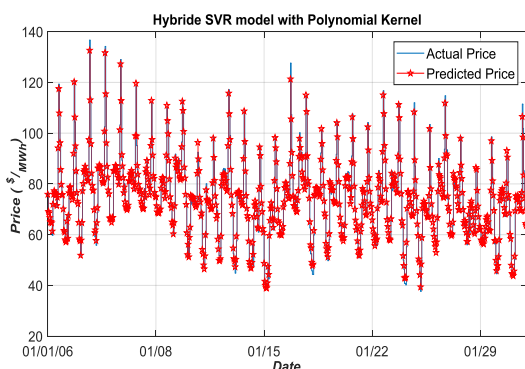


شکل (۹): عملکرد شبکه عصبی در مینیم کردن خطا



شکل (۱۰): نمودارهای رگرسیون شبکه عصبی

نتایج پیش‌بینی قیمت برق برای ماه ژانویه با مدل‌های جدول (۴) به ترتیب در شکل‌های (۱۱) و (۱۲) نشان داده شده‌اند. با مقایسه مقادیر جدول (۴) و نمودارهای (۱۱) و (۱۲) به این نتیجه می‌رسیم که مدل ترکیبی پیشنهادی با استفاده از ماشین‌های بردار پشتیبان با کرنل چندجمله‌ای بهترین عملکرد را در پیش‌بینی ماه - پیش قیمت برق داشته است.



شکل (۱۱): نتایج واقعی و پیش‌بینی شده برای ماه ژانویه ۲۰۰۶ با استفاده از مدل ترکیبی پیشنهادی با بردار پشتیبان

درصد خطا و بهبود نتایج پیش‌بینی شده است. نتایج به‌دست‌آمده نشان می‌دهند به جز بردار پشتیبان با کرنل خطی، برای باقی مدل‌های بردار پشتیبان استفاده از روش پیشنهادی در این مقاله علاوه بر کاهش خطا موجب افزایش سرعت آموزش مدل‌ها شده است.

برای مقایسه دقت مدل پیشنهادی، از شبکه عصبی پیش‌خور دولایه استفاده شده است. در این مدل داده‌های ورودی، ویژگی‌های انتخاب‌شده اتوانکدرها و هدف، قیمت برق است. مقایسه نتایج آموزش شبکه عصبی با بهترین مدل ماشین بردار پشتیبان یعنی مدل با تابع کرنل چندجمله‌ای، در جدول (۴) نشان داده شده است.


برای مقایسه بیشتر نتایج از مرجع شماره [۴۴] در پیش‌بینی ماه - پیش قیمت ساعتی برق در بازار استرالیا استفاده شده است. داده‌های آموزش مربوط به سال ۲۰۰۵ در بازار استرالیا و داده‌های آزمایش مربوط به ماه ژانویه سال ۲۰۰۶ است. نتایج جدول (۴) توانایی روش پیشنهادی را در کاهش مقدار خطای پیش‌بینی در مقایسه با روش مرجع [۴۴] نشان می‌دهند. شکل (۹) عملکرد شبکه عصبی در مینیم کردن خطای مدل و شکل (۱۰) نمودار رگرسیون آن در سه مرحله آموزش، اعتبارسنجی و آزمایش را نشان می‌دهد.

جدول (۴): مقایسه نتایج مدل‌های شبکه عصبی و بردار پشتیبان

مدل	MSE	MAPE(%)
توپولوژی ترکیبی موازی شبکه عصبی [۴۴]	۴/۱۱	۱/۴۲
مدل ترکیبی با بردار پشتیبان با کرنل چندجمله‌ای (روش پیشنهادی)	۱/۲۱	۱/۱۱
مدل ترکیبی با شبکه عصبی (روش پیشنهادی)	۳/۲۳	۱/۹۹

مراجع

- [1] A.Motamedi, H. Zareipour, and W. D. Rosehart, "Electricity price and demand forecasting in smart grids," IEEE Trans. Smart Grid, vol. 3, No. 2., pp. 664-674, Jun. 2012.
- [2] M. Shahidehpour, H. Yamin, Z. Li, "Market Operations in Electric Power Systems, Tarbiat modares university, 1384.
- [3] I.I.Nadtokaa, M. Al-Zihery Balasim, "Mathematical modeling and short-term forecasting of electricity consumption of the power system, with due account of air temperature and natural illumination, based on support vector machine and particle swarm," Elsevier International Conference on Industrial Engineerin 2015.
- [4] X. Yan ,N.A. Chowdhury "Mid-term electricity market clearing price forecasting using multiple least squares support vector machines," IET Generation, Transmission & Distribution, Vol. 8, No. 9, pp-1572-1582, Sept. 2014.
- [5] Y.H. Chen, W.C. Hong, W. Shen, N.N. Huang, "Electric Load Forecasting Based on a Least Squares Support Vector Machine with Fuzzy Time Series and Global Harmony Search Algorithm," MDPI energies, Vol. 9, No. 2, pp. 1-13, January 2016.
- [6] W. Guo, Z. Zhao, "A Novel Hybrid BND-FOA-LSSVM Model for Electricity Price Forecasting," MDPI Information, Vol. 8, No. 4, pp. 1-16, September 2017.
- [7] P.H. Kuo, C.J. Huang, "An Electricity Price Forecasting Model by Hybrid Structured Deep Neural Networks," MDPI Sustainability, Vol. 10, No. 4, pp. 1-17, April 2018.
- [8] M. Rafiei, T. Niknam, M. Khooban, "Probabilistic Forecasting of Hourly Electricity Price by Generalization of ELM for Usage in Improved Wavelet Neural Network," IEEE Trans. Industrial Informatics., Vol. 13, No. 1, pp. 71-79, Feb. 2017.
- [9] R. Tahmasebifar, M. Sheikh-El-Eslami, R. Kheirollahi, "Point and interval forecasting of real-time and day-ahead electricity prices by a novel hybrid approach," IET Generation, Transmission & Distribution, Vol. 11, No. 9, pp. 2173-2183, June. 2017.
- [10] B. Uniejewski, R. Weron and F. Ziel, "Variance Stabilizing Transformations for Electricity Spot Price Forecasting," IEEE Trans. Power Syst., Vol. 33, No. 2, pp. 2219-2229, March. 2018.
- [11] A. Bello, D. W. Bunn, J. Reneses, A. Muñoz, "Medium-Term Probabilistic Forecasting of Electricity Prices: a Hybrid Approach," IEEE Trans. Power Syst., Vol. 32, No. 1, pp. 334-343, Jan. 2017.
- [12] "Strategic research agenda for Europe's electricity networks of the future," 2007, EUR 22580, European Technology Platform SmartGrids.
- [13] L. Zhang and P. B. Luh, "Neural network-based market clearing price prediction and confidence interval estimation with an improved extended Kalman filter method," IEEE Trans. Power Syst., Vol. 20, No.1, pp. 59-66, Feb. 2005.



شکل (۱۲): نتایج واقعی و پیش‌بینی شده برای ماه ژانویه ۲۰۰۶ با استفاده از مدل ترکیبی با شبکه عصبی

۴- نتیجه گیری

در این مقاله روش ترکیبی پیش‌بینی میان‌مدت قیمت برق براساس روش‌های یادگیری ماشین ارائه شده است. روش پیشنهادی در این مقاله برای آموزش مدل‌های پیش‌بینی، ترکیب آموزش نظارت‌نشده و آموزش نظارت‌شده است. برای مقایسه نتایج به‌دست‌آمده در این مقاله با سایر کارهای مشابه، روش پیشنهادی با نتایج به‌دست‌آمده از روش ترکیب توپولوژی‌های مختلف شبکه عصبی مصنوعی مقایسه شده است و نتایج به‌دست‌آمده نشان می‌دهند در پیش‌بینی میان‌مدت ماه - پیش استفاده از مدل ترکیبی با بردار پشتیبان دقت بیشتری دارد. نتایج شبیه‌سازی با استفاده از روش پیشنهادی حاکی از این است که این روش علاوه بر مؤثر بودن در کاهش شایان توجه خطای پیش‌بینی، موجب افزایش سرعت آموزش مدل‌ها نیز می‌شود. با توجه به اهمیت دقت پیش‌بینی در مطالعات میان‌مدت، روش پیشنهادی می‌تواند به‌عنوان ابزاری توانمند استفاده شود. در ادامه این مطالعه، استفاده از روش‌های بهینه‌سازی برای محاسبه مقادیر بهینه پارامترهای ماشین بردار پشتیبان همزمان با استفاده از آموزش بدون نظارت پیشنهاد می‌شود. پیشنهاد دیگر، استفاده همزمان از آموزش بدون نظارت و شبکه عصبی مصنوعی پیچیده همراه با ترکیب چندین پیش‌بینی است. استفاده از مدل‌های یادگیری ماشین برای تولید چندین پیش‌بینی، انتخاب بهترین پیش‌بینی‌ها و ترکیب آنها نیز کاری است که می‌توان در ادامه این پژوهش به آن پرداخت.

- electricity markets," *Int. J. Elec. Power & Energy. Syst.*, Vol. 55, pp. 41-50, 2014.
- [29] K. He, Y. Xu, Y. Zou and L. Tang, "Electricity price forecasts using a curvelet denoising based approach," *Physica A: Statistical Mechanics and its Applications*, Vol. 425, pp. 1-9, 2015.
- [30] C. Wan, M. Niu, Y. Song and Z. Xu, "Pareto optimal prediction intervals of electricity price," *IEEE Trans. Power Syst.* in press, 2016.
- [31] F. Parasciv, S. Fleten and M. Schürle, "A spot-forward model for electricity prices with regime shifts," *Energy Econ.*, Vol. 47, pp. 142-153, 1 2015.
- [32] P. Gaillard, Y. Goude and R. Nedellec, "Additive models and robust aggregation for GEFCom2014 probabilistic electric load and electricity price forecasting," *Int. J. Forecast.*, 2016, in press.
- [33] F. Ziel, "Forecasting electricity spot prices using lasso: On capturing the autoregressive intraday structure," *IEEE Trans. Power Syst.*, 2016, in press.
- [34] T. Hong, P. Pinson, S. Fan, H. Zareipour, A. Troccoli and R.J. Hyndman, "Probabilistic energy forecasting: Global energy forecasting competition 2014 and beyond," *Int.J.Forecast.* 2016.
- [35] P. Gaillard, Y. Goude and R. Nedellec, "Additive models and robust aggregation for GEFCom2014 probabilistic electric load and electricity price forecasting," *Int. J. Forecast.*, 2016, in press.
- [36] F. Ziel, "Forecasting electricity spot prices using lasso: On capturing the autoregressive intraday structure," *IEEE Trans. Power Syst.*, 2016, in press.
- [37] Y. Yang, Y. Dong, Y. Chen and C. Li, "Intelligent optimized combined model based on GARCH and SVM for forecasting electricity price of New South Wales, Australia," in *Abstr. Appl. Anal.*, Vol. 2014, Article ID 504064, 2014.
- [38] X. Yan and N. A. Chowdhury, "Mid-term electricity market clearing price forecasting: A multiple SVM approach," *Int. J. Elec. Power*, Vol. 58, pp. 206-214, 2014.
- [39] X. Yan and N. A. Chowdhury, "Hybrid SVM & ARMAX based mid-term electricity market clearing price forecasting," in *IEEE Conf. Electrical Power & Energy Conference (EPEC)*, pp. 1-5, 2013.
- [40] R. Weron, "Electricity price forecasting: A review of the state-of-the-art with a look into the future," *Int.J.Forecast.*, Vol. 30, No. 4, pp. 1030-1081 2014.
- [41] Goodfellow, L., Bengio, Y., Courville, A., *Deep Learning*, The MIT Press, November 18, 2016.
- [42] Bishop, C. M., *Pattern Recognition and Machine Learning*, Springer, 2006.
- [43] Osorio, G. J., Matis, J.C.O., Catalao, J.P.S., "Electricity prices forecasting by a hybrid evolutionary-adaptive methodology," *Energy Conversion and Management*, Vol.80, pp. 363-373, April. 2014.
- [44] Hossam, M., El-Hawary, M., "Hourly Electricity Price Forecasting for the Next Month Using Multilayer Neural Network," *IEEE Canadian journal of electrical and computer engineering*, Vol.39, No. 4, pp. 283-291, December. 2016.
- [45] (2015). The Australian Energy Market Operator (AEMO).
- [14] J.H. Zhao, Z. Y. Dong, Z. Xu, and K. P. Wong, "A statistical approach for interval forecasting of the electricity price," *IEEE Trans. Power Syst.*, Vol. 23, No. 2, pp. 267-276, May 2008.
- [15] X. Chen, Z. Y. Dong, K. Meng, Y. Xu, K. P. Wong, and H. W. Ngan, "Electricity price forecasting with extreme learning machine and Bootstrapping," *IEEE Trans. Power Syst.*, Vol. 27, No. 4, pp. 2055-2062, Nov. 2012.
- [16] K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximators," *Neural Netw.*, Vol. 2, No. 5, pp. 359-366, 1989.
- [17] J. T. G.Hwang and A. A.Ding, "Prediction intervals for artificial neural networks," *J. Amer. Stat. Assoc.*, Vol. 92, No. 438, pp. 748-757, Jun. 1997.
- [18] R. D. De Veaux, J. Schumi, J. Schweinsberg, and L. H. Ungar, "Prediction intervals for neural networks via nonlinear regression," *Technometrics*, Vol. 40, No. 4, pp. 273-282, Nov. 1998.
- [19] D. J. C. MacKay, "The evidence framework applied to classification networks," *Neural Comput.*, Vol. 4, No. 5, pp. 720-736, Sep. 1992.
- [20] T. Heskes, "Practical confidence and prediction intervals," *NIPS'96 Proceedings of the 9th International Conference on Neural Information Processing Systems*, Eds. Cambridge, MA, USA: MIT Press, 1997, Vol. 9, pp. 176-182.
- [21] D. A. Nix and A. S. Weigend, "Estimating the mean and variance of the target probability distribution," in *Proc. IEEE Int. Conf. Neural Netw.*, Orlando, FL, USA, 1994, Vol. 1, pp. 55-60.
- [22] R. Dybowski and S. J. Roberts, "Confidence intervals and prediction intervals for feed-forward neural networks," in *Clinical Applications of Artificial Neural Networks*, R. Dybowski and V. Gant, Eds. Cambridge, U.K.: Cambridge Univ. Press, 2001, pp. 298-326.
- [23] G. B. Huang, Q. Y. Zhu, and C.K. Siew, "Extreme learning machine: A new learning scheme of feedforward neural networks," in *Proc. IJCNN*, Budapest, Hungary, Jul. 25-29, 2004, Vol. 2, pp. 985-990.
- [24] G. B. Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, Vol. 70, No. 1-3, pp. 489-501, Dec. 2006.
- [25] L. Hu and G. Taylor, "A novel hybrid technique for short-term electricity price forecasting in UK electricity markets," *J. Int. Counc. Electr. Eng.*, Vol. 4, No. 2, pp. 114-120, 2014.
- [26] S. Voronin and J. Partanen, "Forecasting electricity price and demand using a hybrid approach based on wavelet transform, ARIMA and neural networks," *Int. J. Energy Res.*, Vol. 38, No. 5, pp. 626-637, 2014.
- [27] P. Kou, D. Liang, L. Gao and J. Lou, "Probabilistic electricity price forecasting with variational heteroscedastic gaussian process and active learning," *Energy Conversion and Management*, Vol. 89, No. 0, pp. 298-308, 2015.
- [28] N. A. Shrivastava and B. K. Panigrahi, "A hybrid wavelet-ELM based short term price forecasting for

-
- ¹ Least Squares Support Vector Machine
 - ² Fuzzy Time Series
 - ³ Global Harmony Search Algorithm
 - ⁴ Beveridge-Nelson Decomposition
 - ⁵ Fruit Fly Optimization Algorithm
 - ⁶ Bootstrap
 - ⁷ Nonlinear Conditional Heteroscedastic Forecasting
 - ⁸ quantGAM
 - ⁹ Kullback-Leibler Divergence
 - ¹⁰ Support Vector Machine Regression
 - ¹¹ ϵ -insensitive
 - ¹² Medium Gaussian
 - ¹³ Coarse Gaussian
 - ¹⁴ Fine Gaussian
 - ¹⁵ Polynomial