

Forecasting the Market Clearing Price in Iran's Electricity Market Using Two Deep Learning-Based Hybrid Models¹

Behnam Darabi², Ali Faridzad³, Abdolrasoul Ghasemi⁴

Received: 2025/01/13

Accepted: 2025/03/02

Abstract

Electricity is a unique commodity, and forecasting its price is challenging due to its distinct characteristics. Accurate electricity price forecasting is essential for market participants, as it can help reduce risk, increase economic profitability, and enhance power system stability. In the electricity price forecasting literature, machine learning models have been preferred over other models due to their ability to capture the nonlinear behavior of market data, ease of implementation, and good performance. In recent years, the emphasis on the importance of the number of hidden layers in machine learning structures has led to the emergence of deep learning. However, the performance of these models is significantly influenced by optimal feature selection and appropriate hyperparameter tuning. Therefore, this study aims to forecast the market clearing price in Iran's electricity market by employing two deep learning-based hybrid models: deep neural networks (DNN) and long short-term memory (LSTM) networks, using feature selection and hyperparameter optimization techniques. The forecasting accuracy of the models is then compared. The results indicate that the LSTM-based hybrid model outperforms the DNN-based model.

Keywords: Market Clearing Price, Iranian Electricity Market, Deep Learning.

JEL Classification: C61, C63, D44, Q47.

1. doi: 10.22051/ieda.2025.50030.1459

2. M.Sc. Student, Department of Energy Economics, Faculty of Economics, Allameh Tabataba'i University, Tehran, Iran. Email: behnamdarabi480@gmail.com.

3. Associate Professor, Department of Energy, Agricultural and Environmental Economics, Faculty of Economics, Allameh Tabataba'i University, Tehran, Iran. Corresponding Author. Email: ali.faridzad@atu.ac.ir.

4. Associate Professor, Department of Energy, Agricultural and Environmental Economics, Faculty of Economics, Allameh Tabataba'i University, Tehran, Iran. Email: a.ghasemi@atu.ac.ir.

مقاله پژوهشی

پیش‌بینی قیمت تسویه بازار برق ایران با استفاده از دو مدل ترکیبی مبتنی بر یادگیری عمیق^۱

بهنام دارابی^۲، علی فریدزاد^۳، عبدالرسول قاسمی^۴

تاریخ پذیرش: ۱۴۰۳/۱۲/۱۲

تاریخ دریافت: ۱۴۰۳/۱۰/۲۴

چکیده

برق کالایی منحصر به فرد است که پیش‌بینی آن به دلیل ویژگی‌های متمایز و متفاوت آن، کاری دشوار و چالش‌برانگیز است. از طرفی پیش‌بینی دقیق آن برای فعالان حاضر در بازار برق بسیار حائز اهمیت است؛ چراکه می‌تواند در کاهش سطح ریسک، افزایش سود اقتصادی و پایداری سیستم قدرت مؤثر باشد. در ادبیات پیش‌بینی قیمت برق، از میان مدل‌های مختلفی که برای پیش‌بینی وجود دارد، مدل‌های مبتنی بر یادگیری ماشین به سبب توانایی آن‌ها در الگو کردن رفتار غیرخطی داده‌های بازار برق و اجرای آسان و عملکرد مناسب آن‌ها، به سایر مدل‌ها ترجیح داده می‌شوند. در سال‌های اخیر نیز، تأکید بر اهمیت تعداد لایه‌های پنهان در ساختار مدل‌های یادگیری ماشین، منجر به شکل‌گیری گرایش یادگیری عمیق شده است. از طرفی عملکرد مدل‌های یادشده تحت تأثیر انتخاب بهینه زیرمجموعه ویژگی‌ها و نیز تنظیمات مناسب هاپرپارامترها است. از این‌رو مطالعه حاضر با هدف پیش‌بینی قیمت‌ها در بازار برق ایران، با استفاده از تکنیک‌های انتخاب ویژگی بهینه و بهینه‌سازی هاپرپارامترها، دو مدل مبتنی بر یادگیری عمیق از نوع شبکه‌های عصبی عمیق و حافظه‌های طولانی کوتاه‌مدت ارائه می‌دهد و دقت آن‌ها را با یکدیگر مقایسه می‌کند. نتایج نشان‌دهنده برتری مدل ترکیبی مبتنی بر حافظه‌های طولانی کوتاه‌مدت بر دیگری است.

واژگان کلیدی: قیمت تسویه بازار، بازار برق ایران، یادگیری عمیق.

طبقه‌بندی موضوعی: C61، C63، D44، Q47.

۱. کد DOI مقاله: 10.22051/ieda.2025.50030.1459

۲. دانشجوی کارشناسی ارشد، گروه اقتصاد انرژی، دانشکده اقتصاد، دانشگاه علامه طباطبائی، تهران، ایران.
Email: behnamdarabi480@gmail.com

۳. دانشیار، گروه اقتصاد انرژی، کشاورزی و محیط زیست، دانشکده اقتصاد، دانشگاه علامه طباطبائی، تهران، ایران.
Email: ali.faridzad@atu.ac.ir نویسنده مسئول.

۴. دانشیار، گروه اقتصاد انرژی، کشاورزی و محیط زیست، دانشکده اقتصاد، دانشگاه علامه طباطبائی، تهران، ایران.
Email: a.ghasemi@atu.ac.ir

مقدمه

برق کالایی است که ذخیره‌سازی آن اقتصادی نیست، نیازمند تعادل ثابت میان عرضه و تقاضا به‌منظور حفظ پایداری شبکه است، تولید آن تحت تأثیر شرایط آب‌وهوایی قرار دارد و تقاضای آن بی‌کشش و وابسته به ساعات روز، هفته و ایام سال است. مجموعه ویژگی‌های یادشده منجر به ایجاد نوسانات شدید و اوج‌های ناگهانی و غیرمنتظره، میانگین و واریانس غیر ثابت و رفتار فصلی در سطوح مختلف روزانه، هفتگی و سالانه در قیمت‌ها و در نتیجه پیش‌بینی دشوار آن می‌شود. در راستای مقابله با چالش‌های یادشده، پیش‌بینی قیمت‌ها در بازارهای برق در کانون توجه محققان حوزه انرژی قرار گرفته است (ژانگ و همکاران، ۲۰۱۹؛^۱ اوگورلو و همکاران، ۲۰۱۸؛^۲ لاگو و همکاران، ۲۰۱۸؛^۳ الف و لاگو و همکاران، ۲۰۱۸؛^۴ آب و ورون، ۲۰۱۴؛^۵ آگاروال و همکاران، ۲۰۰۹؛^۶ امجدی و همتی، ۲۰۰۶).

پس از تجدید ساختار و آزادسازی در صنعت برق، پیش‌بینی دقیق قیمت‌های برق برای فعالان حاضر در بازار برق، بنا بر سه دلیل کلیدی، از اهمیت ویژه‌ای برخوردار شده است. نخست آنکه در چارچوب اقتصاد خرد و در سطح بنگاه، پیش‌بینی دقیق قیمت برق نقشی اساسی در فرآیند تصمیم‌گیری شرکت‌های فعال در حوزه انرژی ایفا می‌کند. نوسانات بسیار شدید قیمت برق — که در برخی موارد تا صد برابر بیش‌تر از نوسانات سایر کالاها یا دارایی‌های مالی برآورد شده است — موجب شده است تا فعالان بازار، نه تنها در برابر ریسک مقدار، بلکه در برابر نوسانات قیمتی نیز اقدام به پوشش ریسک کنند. بر این اساس، ضرورت پیش‌بینی دقیق قیمت برق در بازه‌های زمانی مختلف، برای بازیگران بازار بیش از پیش محسوس است. یک نیروگاه، شرکت برق یا مصرف‌کننده بزرگ صنعتی، در صورتی که بتواند پیش‌بینی دقیقی از قیمت‌های عمده‌فروشی برق — که با نوسانات شدید همراه است — ارائه دهد، خواهد توانست سیاست‌های پیشنهاد قیمت و نیز برنامه‌ریزی تولید یا مصرف خود را به‌گونه‌ای تنظیم کند که ریسک کاهش یابد یا سود حاصل از معاملات روز بعد به حداکثر برسد (ژانگ و همکاران؛ ۲۰۱۹؛ لاگو و همکاران، ۲۰۱۸؛ اوگورلو و همکاران، ۲۰۱۸؛ کلس و همکاران، ۲۰۱۶؛^۸ ورون و همکاران، ۲۰۱۴؛ آگاروال و همکاران، ۲۰۰۹). دوم آنکه بازارهای برق اساساً با هدف کمک به حفظ پایداری سیستم^۹ از طریق ایجاد تعادل میان تولید و مصرف برق، طراحی و راه‌اندازی شده‌اند. به‌ویژه آن‌که با افزایش نوسانات قیمت، تعادل شبکه به خطر می‌افتد و در نتیجه، احتمال استفاده از ذخایر راهبردی و خطر بروز خاموشی افزایش می‌یابد (لاگو و همکاران، ۲۰۱۸). در همین راستا، باید توجه داشت که خسارات ناشی از خاموشی، محدود به صنعت برق نیست؛ بلکه ابعاد آن بسیار

1. Zhang *et al.*
2. Ugurlu *et al.*
3. Lago *et al.*
4. Lago *et al.*
5. Weron
6. Aggarwal *et al.*
7. Amjadi & Hemmati
8. Keles *et al.*
9. System Stability



گسترده تر و فراتر از این حوزه است. وقوع خاموشی می تواند به توقف فعالیت در سایر صنایع، کاهش تولید کل و اختلال در انجام معاملات الکترونیکی منجر شود. علاوه بر این، زندگی روزمره شهروندان نیز با چالش هایی جدی مواجه می گردد. در مواردی که قطعی برق به صورت بلندمدت یا مکرر رخ دهد، این وضعیت می تواند زمینه ساز شکل گیری اضطراب و نگرانی در میان مردم شود. از این رو، خاموشی های برق علاوه بر زیان هایی که به صنعت برق وارد می کند، دارای پیامدهای اقتصادی و اجتماعی گسترده ای در سطح کل جامعه است؛ پیامدهایی که در بسیاری از موارد، برآورد دقیق آن ها دشوار و حتی ناممکن است. بدیهی است که خاموشی های گسترده با بند هفتم اهداف توسعه پایدار سازمان ملل متحد - که بر دسترسی همگانی به انرژی مطمئن^۱ تأکید دارد - نیز، در تضاد قرار دارد؛ بنابراین، با پیش بینی دقیق قیمت برق، نه تنها امکان کسب سود اقتصادی فراهم می شود، بلکه با کمک به حفظ تعادل عرضه و تقاضا، پایداری سیستم نیز ارتقاء می یابد؛ در نتیجه، احتمال وقوع خاموشی ها، اختلال در فعالیت های اقتصادی و آسیب های اجتماعی ناشی از ناپایداری شبکه کاهش می یابد و بدین ترتیب، گامی مؤثر در راستای تحقق توسعه پایدار برداشته می شود (صالح و همکاران، ۲۰۲۴؛ شوائ و همکاران، ۲۰۱۸؛ لاگو و همکاران، ۲۰۱۸؛ سازمان ملل متحد، ۲۰۱۵). در توضیح دلیل سوم به نحوه پرداخت در بازارهای برق اشاره می شود. در صورتی که نظام پرداختی در بازار، مبتنی بر پیشنهاد^۵ باشد، عرضه کننده قیمتی را دریافت می کند که وی برای مقادیر مشخص پیشنهاد داده است. از این رو، در چنین نظام پرداختی، سود عرضه کننده مستقیماً تحت تأثیر پیشنهاد او است. در نظام پرداختی یادشده، پیش بینی دقیق قیمت ها در مقایسه با نظام پرداختی مبتنی بر قیمت واحد^۶ که مبنای پرداخت، قیمت تسویه است، اهمیت بیشتری دارد (حیدرپناه و همکاران، ۲۰۲۳؛ ورون و همکاران، ۲۰۱۴؛ نیلسن، ۲۰۱۱).

فرآیند تجدید ساختار و آزادسازی صنعت برق ایران در سال ۱۳۸۲ با تدوین آیین نامه بازار برق و خصوصی سازی نیروگاه ها آغاز گردید. بازار برق ایران از نوع بازار عمده فروشی است که ساختار آن مبتنی بر مدل آژانس خرید یا همان حراج یک طرفه است؛ به این معنا که شرکت مدیریت شبکه برق ایران در جایگاه شرکت عامل یا همان آژانس خرید عمل می کند. لازم به توضیح است که در بازار برق ایران، هیچ رقابتی در سطح خرده فروشی انجام نمی شود. در بازار مزبور، حضور کلیه فعالان در بازار برق ایران الزامی است. بر اساس زمان، بازار برق ایران از نوع روز بعد است؛ به این معنا که نقطه تسویه بازار و لیست برندگان فروش، یک روز پیش از تحویل، مشخص و به اطلاع فعالان بازار رسانیده می شود. لازم به توضیح است که نظام

1. Reliable Energy
2. Saleh *et al.*
3. Shuai *et al.*
4. United Nations
5. Pay-as-Bid
6. Uniform-Price
7. Heidarpnahan *et al.*
8. Nielsen *et al.*



پرداخت در ایران، مبتنی بر پیشنهاد است (دفتر مطالعات اقتصادی و توسعه بازار برق، ۱۳۹۳؛ ابونوری و لاجوردی، ۱۳۹۲). نظر به آنچه در شرح فرآیند بازار برق ایران گفته شد، استدلال‌های اول، دوم و سوم در توضیح اهمیت پیش‌بینی دقیق قیمت برق برای صنعت برق ایران نیز صدق می‌کند.

ادبیات پیش‌بینی قیمت برق به ۵ حوزه ۱- مدل‌های نظریه بازی^۱، ۲- روش‌های بنیادی^۲، ۳- مدل‌های فرم تقلیل‌یافته^۳، ۴- مدل‌های آماری^۴ و ۵- مدل‌های یادگیری ماشین^۵ تقسیم می‌شود که در میان آن‌ها مدل‌های آماری و یادگیری ماشین در مقایسه با سایر روش‌ها به نتایج بهتری دست پیدا کرده‌اند (لاگو و همکاران، ۲۰۱۸؛ الف؛ اوگورلو و همکاران، ۲۰۱۸؛ ورون، ۲۰۱۴). یکی از نقاط ضعف مدل‌های آماری آن است که مدل‌های یادشده معمولاً پیش‌بینی‌کننده‌های خطی هستند؛ به همین دلیل ممکن است برای داده‌های با فرکانس بالا و نوسانات شدید، مانند داده‌های ساعتی عملکرد ضعیفی داشته باشند (مددخانی و ایکونیکووا، ۲۰۲۴؛ جدرژیفسکی و همکاران، ۲۰۲۲؛ کاستا و همکاران، ۲۰۲۱؛ ژانگ و همکاران، ۲۰۱۹؛ لاگو و همکاران، ۲۰۱۸؛ الف؛ لاگو و همکاران، ۲۰۱۸؛ ورون، ۲۰۱۴؛ آگاروال و همکاران، ۲۰۰۹؛ امجدی و همتی، ۲۰۰۶). از این‌رو مدل‌های یادگیری ماشین که یک جایگزین با قابلیت‌های پیشرفته و اجرای آسان برای روش‌های آماری به حساب می‌آیند و در مدیریت مجموعه داده‌های بزرگ و الگوهای غیرخطی عملکرد بسیار خوبی دارند، پیشنهاد می‌شوند (مددخانی و ایکونیکووا، ۲۰۲۴). با نوآوری‌های شکل‌گرفته در حوزه شبکه‌های عصبی، محققان گونه‌ای جدید از این شبکه‌ها با عنوان شبکه‌های عصبی عمیق (DNN)^۹ را معرفی کرده‌اند که عمق آن‌ها تنها به یک لایه پنهان محدود نمی‌شود. از آنجایی که ساختارهای جدید مرتباً نتایج و قابلیت‌های تعمیم بهتری را نشان می‌دادند، این رشته به یادگیری عمیق^{۱۰} تغییر نام داد تا بر اهمیت عمق لایه‌های پنهان در پیشرفت‌های به‌دست‌آمده تأکید شود. به‌عنوان نمونه‌ای دیگر از مدل‌های یادگیری عمیق، می‌توان به شبکه‌های عصبی بازگشتی اشاره داشت که کمی پیچیده‌تر از شبکه‌های عصبی عمیق هستند و قادر به حفظ اطلاعات از ورودی‌های گذشته هستند. با هدف فائق آمدن بر مشکل محوشدگی گرادیان‌ها در انواع ساده‌تر شبکه‌های عصبی بازگشتی^{۱۱}، نسخه‌های بهبودیافته آن‌ها نظیر حافظه‌های طولانی کوتاه‌مدت (LSTM)^{۱۲} معرفی شده‌اند (لاگو و همکاران، ۲۰۱۸؛ الف).

1. Game Theory Models
2. Fundamental Methods
3. Reduced-Form Models
4. Statistical Models
5. Statistical Models
6. Madadkhani & Ikonnikova
7. Jedrzejewski *et al.*
8. Costa *et al.*
9. Deep Neural Networks (DNN)
10. Deep Learning (DL)
11. Recurrent Neural Networks (RNN)
12. Long Short-Term Memory (LSTM)



بر اساس آنچه پیش تر بیان شد، مطالعه حاضر با هدف دستیابی به یک پیش بینی دقیق در بازار برق عمده فروشی ایران که از منظر اقتصادی می تواند زمینه ساز کاهش ریسک، بهبود تصمیم گیری اقتصادی و حفظ پایداری سیستم شود — پایداری ای که خود می تواند به عنوان زیرساخت حیاتی اقتصاد عمل کند — به معرفی و مقایسه دو مدل از خانواده یادگیری عمیق می پردازد. هم چنین در این مطالعه به منظور بهبود عملکرد مدل های پیش بینی ارائه شده، از روش های انتخاب ویژگی با قابلیت در نظر گرفتن رفتار غیرخطی داده ها به منظور ایجاد یک زیرمجموعه بهینه از مجموعه اولیه ویژگی ها و نیز یک الگوریتم بهینه سازی با هدف دستیابی به هایپرپارامترهای مناسب و بهینه استفاده می شود.

دو مدل ترکیبی نوآورانه ارائه شده که هر یک به صورت مستقل طراحی و پیاده سازی شده اند، از چند منظر نسبت به مطالعات انجام شده در ایران دارای ویژگی های متمایز و نوین هستند: نخست آن که مطالعه حاضر به مقایسه دقت پیش بینی دو نمونه از مدل های یادگیری عمیق؛ یعنی یک شبکه عصبی عمیق (DNN) به عنوان مدل پایه ای یادگیری عمیق و نیز یک حافظه طولانی کوتاه مدت (LSTM) به عنوان مدل پیشرفته تر یادگیری عمیق در بازار برق ایران می پردازد و پس از آن، نتایج مقایسه را به لحاظ معناداری آماری نیز مورد بررسی قرار می دهد. این در حالی است که حیدرپناه و همکاران (۲۰۲۳)، به عنوان تنها مطالعه ای که از یادگیری عمیق در پیش بینی قیمت برق ایران بهره برده است، فقط از یک مدل یادگیری عمیق، یعنی LSTM در مطالعه خود استفاده می کنند و در مقایسه آن با سایر روش های آماری و یادگیری، بررسی معناداری آماری مغفول مانده است. دوم آن که برخلاف مطالعات حیدرپناه و همکاران (۲۰۲۳) و ناظمی و همکاران (۱۳۹۷) که از روش های انتخاب ویژگی خطی برای انتخاب مقادیر بهینه وقفه قیمت استفاده می کنند، مطالعه حاضر، رفتار غیرخطی داده های بازار برق ایران را لحاظ می کند. جزئیات رویکرد مزبور در بخش روش شناسی ذکر شده است. سوم آن که پژوهش فعلی به منظور انتخاب تنظیمات مناسب هایپرپارامترهای مدل های مورد استفاده، از الگوریتم بهینه سازی متفاوت نسب به سایر مطالعات پیش بینی قیمت در بازار برق ایران استفاده می کند. این الگوریتم با جزئیات آن در بخش روش شناسی تشریح می شود. در آخر، مطالعه حاضر با هدف غلبه بر ضعف محدودیت داده در مطالعات پیش بینی قیمت ها در بازار برق ایران که بنا بر گفته ورون (۲۰۱۴)، لاگو و همکاران (۲۰۲۱) و آگاروال (۲۰۰۹) منجر به نتایج غیرقابل اتکا می شود، از داده های با اندازه مناسب استفاده می کند؛ به نحوی که دوره آزمایش این مطالعه بیش تر از یک سال است.

مطالب این مطالعه در چند بخش سازمان دهی شده است. بخش بعدی به بیان مبانی نظری بازارهای برق می پردازد. بخش سوم به مرور مطالعات تجربی در این حوزه اختصاص دارد. بخش چهارم روش شناسی پژوهش را شامل می شود. بخش پنجم تحلیل داده ها و نتایج تجربی را در نظر می گیرد و در نهایت نتیجه گیری و جمع بندی در بخش ششم ارائه می گردد.

مبانی نظری

به دنبال تجدید ساختار و آزادسازی در صنعت برق، این صنعت به یک محیط رقابتی که در آن نیروهای بازار قیمت برق را هدایت می‌کنند، تبدیل شده است (شاهیده‌پور و همکاران^۱، ۲۰۰۲). در امتداد مباحث مطرح‌شده در مقدمه، پیرامون ضرورت پیش‌بینی دقیق قیمت برق و نیز ادبیات رایج در این حوزه، بخش حاضر به تبیین اصول و مفاهیم پایه‌ای در بازارهای برق با هدف درک رابطه بین این مفاهیم و کاربردهای آن‌ها در صنعت و بازارهای برق و نیز شناخت قوانین حاکم در بازار می‌پردازد. مفاهیم یادشده که زیربنای پیش‌بینی قیمت را تشکیل می‌دهند، مدل‌های رایج بازار برق، فعالان حاضر در بازار، سازوکار قیمت‌گذاری و بازارهای مختلف در این صنعت را شامل می‌شود.

۱. مدل‌های بازار برق

در راستای دستیابی به اهداف تضمین عملیات امن و تسهیل عملیات اقتصادی در ایجاد بازار برق، سه مدل برای بازار برق قابل تعریف است. نخستین مدل حوضچه^۲ است که یک بازارگاه متمرکز است. در حوضچه، فروشندگان و خریداران برق پیشنهادهای قیمتی خود را ارسال می‌کنند و در نهایت بهره‌بردار مستقل^۳ بازار را تسویه می‌کند. مدل دوم، قراردادهای دوجانبه است. در این مدل طرفین قرارداد راجع به ارسال و دریافت برق توافق می‌کنند. در مدل یادشده کسب تاییدیه از بهره‌بردار مستقل مبنی بر امکان اجرای قرارداد و تضمین امنیت شبکه ضروری است. در مدل سوم که ترکیبی از دو مدل پیشین است استفاده از حوضچه ضرورتی ندارد و خریدار می‌تواند از طریق مذاکره نیز مستقیماً برق مورد نیاز خود را خریداری کند (شاهیده‌پور و همکاران، ۲۰۰۲).

۲. بازیگران بازار برق

در بازار برق بازیگران مختلفی فعالیت دارند. بهره‌بردار مستقل، شرکت‌های تولید، انتقال، توزیع و مشتریان یا مصرف‌کنندگان نهایی از مهم‌ترین فعالان بازار برق به شمار می‌آیند. بهره‌بردار نهادی مستقل است که وظیفه مدیریت و کنترل شبکه را بر عهده دارد. در حالت کلی دو ساختار حداقلی و حداکثری برای بهره‌بردار مستقل تعریف می‌شود. در ساختار حداکثری، بهره‌بردار مستقل علاوه بر حفظ امنیت و برنامه‌ریزی انتقال، از طریق برگزاری مزایده^۴ در بورس برق^۵ به ایجاد یک بازار رقابتی کمک می‌کند. دومین بازیگر مهم، شرکت‌های تولید هستند که وظیفه مدیریت و نگهداری نیروگاه‌ها را بر عهده دارند. شرکت‌های تولید می‌توانند برق تولیدی خود را در قالب قراردادهای فروش و یا از طریق بورس برق به فروش برسانند. لازم

1. Shahidehpour et al.
2. Pool model
3. Independent System Operator (ISO)
4. Auction
5. Power Exchange (PX)



به ذکر است که در یک محیط رقابتی، شرکت های تولید ساختار ادغام عمودی^۱ ندارند؛ بنابراین قیمت گذاری دستوری نیز برای آنها وجود ندارد. هم چنین آنها نمی توانند تعیین قیمت کنند و یا از طریق قراردادهای دوجانبه، بازار را به نفع خود انحصاری کنند. بازیگر سوم، شرکت های انتقال است که به مثابه مهم ترین عنصر بازارهای برق عمل می کنند. یک شرکت انتقال، برق فشار قوی را از شرکت های تولید در شبکه سراسری انتقال که یک شبکه یکپارچه است، دریافت می کند و به شرکت های توزیع تحویل می دهد. شرکت های انتقال که در یک ساختار یکپارچه ادغام عمودی قرار می گیرند، با دریافت هزینه بابت دسترسی به شبکه، هزینه های سرمایه گذاری و بهره برداری خود را تأمین می کنند. شرکت های توزیع به عنوان چهارمین فعال مهم بازار برق وظیفه اتصال مصرف کننده نهایی به عنوان پنجمین بازیگر بازار برق به شبکه انتقال را بر عهده دارند. شرکت های توزیع هم چنین مسئول خاموشی شبکه توزیع و حفاظت در برابر اضافه ولتاژ هستند. لازم به توضیح است که مصرف کننده نهایی در مقیاس مشتریان عمده و بزرگ می توانند مستقیماً و بدون وساطت سیستم توزیع، به شبکه انتقال متصل شوند (شاهیده پور و همکاران، ۲۰۰۲).

۳. انواع بازار برق بر اساس زمان

بر اساس زمان بازارهای برق به چهار گروه ۱- آتی ها^۲، ۲- روز بعد^۳، ۳- زمان حقیقی (تعادلی)^۴ و ۴- میان روزی^۵ تقسیم می شود. بازار آتی ها امکان انجام معاملات بلندمدت از طریق قراردادهای سلف^۶ و اختیار معامله^۷ را فراهم می کند. معاملات کوتاه مدت که از طریق حوضچه انجام می شود، شامل دو نوع بازار روز بعد و زمان حقیقی است. در بازار روز بعد که یک روز پیش از تحویل انرژی انجام می شود، عرضه کنندگان پیشنهاد های خود شامل مقادیر عرضه و حداقل قیمت های فروش و خریداران، مقادیر تقاضا و حداکثر قیمت های خرید را ارسال می کنند. در نهایت بهره بردار مستقل با استفاده از ابزارهای حراج بازار را تسویه می کند. بازار زمان حقیقی چند دقیقه پیش از تحویل انرژی با هدف تضمین قابلیت اطمینان سیستم های قدرت^۸ انجام می شود. این بازار برای آن دسته از تولید کنندگان که قبل از بسته شدن بازار روز بعد قادر به تعیین سطح دقیق تولید خود نیستند، مناسب است. گروه چهارم از بازارها که میان روزی نام دارد با هدف پوشش بیشتر نا اطمینانی ها در برخی از کشورها شکل گرفته است (مورالس و همکاران، ۲۰۱۴)؛ شاهیده پور و همکاران، ۲۰۰۲).

1. Vertically Integrated Structure
2. Futures Markets
3. Day-Ahead
4. Real-time [Balancing] Market
5. Intra-Day Market
6. Forward
7. Options
8. Power System Reliability
9. Morales *et al.*



۴. قیمت در بازار برق

اساس قیمت‌گذاری در بازار برق، قیمت تسویه بازار^۱ است، بهره‌بردار مستقل پس از دریافت پیشنهادهای از طرفین، پیشنهادهای عرضه را در یک منحنی عرضه کل و پیشنهادهای تقاضا را در یک منحنی تقاضای کل تجمیع می‌کند. قیمت تسویه جایی است که دو منحنی عرضه و تقاضا یکدیگر را قطع می‌کنند (شاهیده‌پور و همکاران، ۲۰۰۲).

۵. مدل‌های رقابت در بازار برق

به‌طور کلی چهار مدل ۱- انحصار، ۲- آژانس خرید، ۳- رقابت عمده‌فروشی و ۴- رقابت خرده‌فروشی وجود دارد. مدل انحصار شامل دو زیرمدل است. در نوع اول، هر سه شرکت تولید، انتقال و توزیع در یک ساختار ادغام عمودی قرار دارند؛ درحالی‌که در نوع دوم آن، شرکت‌های تولید و انتقال که در یک ساختار ادغام عمودی قرار دارند، برق را به یک شرکت توزیع انحصاری واگذار می‌کنند. مدل آژانس خرید اولین گام در راستای تشکیل بازار در صنعت برق است. در این مدل، علاوه بر شرکت برق که نقش تولیدکننده اصلی را ایفا می‌کند، تولیدکنندگان مستقل نیز حضور دارند که برق تولیدی خود را به شرکت عامل یا همان آژانس خرید می‌فروشند. در نسخه بهبودیافته، تنها تولیدکنندگان مستقل برق تولید می‌کنند و شرکت‌های توزیع نیز برق مورد نیاز مشتریان را از آژانس خرید تأمین می‌کنند. در مدل رقابت عمده‌فروشی هیچ سازمانی به‌طور انحصاری مسئول تأمین انرژی نیست و شرکت‌های توزیع، برق مورد نیاز را مستقیماً از شرکت‌های تولید و در بازار عمده‌فروشی تأمین می‌کنند. در این نسخه از رقابت، مصرف‌کنندگان بزرگ اجازه خرید از بازار عمده‌فروشی دارند. در مدل رقابت خرده‌فروشی، همه مصرف‌کنندگان می‌توانند در بازار خرده‌فروشی از تأمین‌کنندگان مورد نظر خود خریداری کنند و شرکت‌های توزیع در تأمین برق مصرف‌کنندگان کوچک انحصار ندارند (کرشن و استراباک، ۲۰۰۴)^۲.

۶. بازار برق ایران

در دو دهه اخیر، صنعت برق در اغلب کشورهای جهان دستخوش تحولات عمیق و ساختاری شده است؛ تحولاتی که تحت عناوینی چون مقررات‌زدایی و تجدید ساختار بخش برق مطرح شده‌اند. در ایران نیز، آغاز به کار بازار برق به‌طور رسمی با ابلاغ آیین‌نامه «تعیین روش، نرخ و شرایط خریدوفروش برق در شبکه برق کشور» توسط وزیر محترم نیرو در آبان ماه ۱۳۸۲ رقم خورد. در ادامه، به‌طور خلاصه به شاخص‌ترین ویژگی‌های بازار برق ایران پرداخته شده است؛ ویژگی‌هایی که در راستای انطباق مفاهیم نظری با واقعیت‌های ساختاری بازار برق ایران و نیز با موضوع پژوهش حاضر تنظیم شده‌اند (دفتر مطالعات اقتصادی و توسعه بازار برق، ۱۳۹۳؛ بازار برق ایران، بدون تاریخ).

1. Market Clearing Price (MCP)
2. Kirschen & Strabac

۱- ساختار فعلی بازار برق ایران، به‌عنوان نمونه‌ای از بازار عمده‌فروشی برق، بر مدل آژانس خرید استوار است؛ الگویی که معمولاً در مراحل ابتدایی گذار به سمت رقابت در بازار برق مورد استفاده قرار می‌گیرد. در این ساختار، شرکت مدیریت شبکه برق ایران به‌عنوان بهره‌بردار مستقل بازار، اقدام به برگزاری حراج یک‌طرفه برای فروشندگان می‌کند، برق مورد نیاز را از تولیدکنندگان دریافت می‌نماید و بر مبنای نتایج تسویه بازار، آن را تخصیص می‌دهد. این ساختار، نمونه‌ای از مدل حوضچه محسوب می‌شود که در آن کلیه معاملات برق در یک بستر متمرکز و از طریق بهره‌بردار مستقل بازار انجام می‌گیرد.

۲- در بازار برق ایران، شرکت مدیریت شبکه برق ایران به‌عنوان آژانس خرید، بر اساس داده‌های پیش‌بینی مصرف بار، به نمایندگی از خریداران، برق مورد نیاز را از تولیدکنندگان تأمین می‌کند. لازم به توضیح است که در بازار برق ایران، برخلاف ساختار رقابت خرده‌فروشی، مصرف‌کنندگان نهایی مستقیماً در فرآیند معاملات بازار حضور نداشته و در قالب بازیگران اصلی یا طرف‌های معامله ظاهر نمی‌شوند.

۳- بازار برق ایران از نظر زمان، یک بازار روز بعد محسوب می‌شود که در آن پرداخت‌ها بر مبنای قیمت‌های پیشنهادی صورت می‌گیرد. در این ساختار، تولیدکنندگان (فروشندگان) پیشنهادهای قیمت و مقدار تولید خود را تا پیش از ساعت ۱۰ صبح روز قبل از بهره‌برداری به بهره‌بردار مستقل بازار ارسال می‌کنند. شرکت مدیریت شبکه برق ایران نیز به‌عنوان بهره‌بردار مستقل، با تجمیع این پیشنهادهای و بر اساس پیش‌بینی مصرف بار، قیمت تسویه بازار را برای هر ساعت تعیین و اعلام می‌نماید.

۴- در بازار برق ایران، بیش از ۱۵۰ نیروگاه فعال هستند. در حال حاضر، حدود ۵۲ درصد از ظرفیت نیروگاه‌های کشور تحت مالکیت بخش خصوصی قرار دارد و سهم باقی‌مانده در اختیار بخش دولتی است. همچنین در ساختار بازار برق ایران، مالکیت بخش‌های انتقال و توزیع برق در انحصار وزارت نیرو و نهادهای تابعه آن قرار دارد.

مروری بر مطالعات تجربی

در زمینه پیش‌بینی قیمت برق مطالعات تجربی گسترده‌ای در سطح داخلی و بین‌المللی صورت گرفته است. در ادامه به تعدادی از این مطالعات اشاره می‌شود.

در حوزه مطالعات بین‌المللی، هوانگ و همکاران (۲۰۲۴)^۱ با استفاده از داده‌های بازار برق استان شاندونگ در چین و به‌کارگیری یک مدل ترکیبی به پیش‌بینی قیمت‌ها در این بازار پرداخته‌اند. داده‌های مورد استفاده در بازه ۱ دسامبر ۲۰۲۱ تا ۳۰ آوریل ۲۰۲۳ قرار دارند. نویسندگان در مدل ترکیبی خود، پس از انتخاب روزهای مشابه، از الگوریتم XGBoost^۲ برای انتخاب بهینه ویژگی‌ها استفاده می‌کنند و در

1. Huang et al.
2. eXtreme Gradient Boosting (XGBoost)

نهایت با استفاده از مدل DNN پیش‌بینی خود را انجام می‌دهند. هایپرپارامترها نیز در این مطالعه با استفاده از یکی از روش‌های بهینه‌سازی بیزی، بهینه و انتخاب می‌شوند. نتایج، نشان‌دهنده برتری مدل ترکیبی در مقایسه با مدل ساده است.

حیدرپناه و همکاران (۲۰۲۳) در پژوهشی به پیش‌بینی حداکثر و میانگین قیمت روزانه در بازار برق ایران پرداخته‌اند. آن‌ها از داده‌های ساعتی قیمت در بازار برق ایران برای سال‌های ۲۰۲۰-۲۰۲۱ استفاده کرده‌اند. هم‌چنین نویسندگان مقادیر بهینه وقفه قیمت را که توسط تحلیل همبستگی ساده تعیین شده‌اند، به‌عنوان متغیرهای ورودی (ویژگی) به کار گرفته‌اند. نتایج نشان می‌دهد که مدل مبتنی بر LSTM بهترین عملکرد، مدل‌های مبتنی بر ANN^۱ و ANFIS^۲ عملکرد متوسط و مدل‌های MLR^۳ و SVM^۴ ضعیف‌ترین عملکرد را در پیش‌بینی هدف داشته‌اند.

مددخانی و ایکونیکووا (۲۰۲۳) با استفاده از داده‌های میانگین قیمت روزانه بازار برق آلمان و ۸۰ متغیر توضیحی دیگر اقدام به پیش‌بینی قیمت برق با مدل‌های یادگیری ماشین تحت سناریوهای مختلف کرده‌اند. داده‌های این مطالعه بازه زمانی ژانویه ۲۰۱۵ تا اکتبر ۲۰۲۱ را شامل می‌شود. محققان به‌منظور انتخاب متغیرهای توضیحی تأثیرگذار و بهینه، الگوریتم‌های مبتنی بر درخت مانند RF^۵، XGBoost^۶ و BART^۷ را با RFE^۸ ادغام کرده‌اند. هدف مطالعه یادشده اثبات برتری الگوریتم‌های انتخابی در پیش‌بینی قیمت برق نیست؛ بلکه هدف آن است تا نشان دهد که می‌توان با استفاده از تنظیمات مناسب به مدل‌های نسبتاً ساده یادگیری ماشین با قابلیت پیش‌بینی مناسب دست یافت.

لاگو و همکاران (۲۰۱۸) با استفاده از داده‌های بازار برق اروپا-بلژیک که برای یک دوره ۶ ساله جمع‌آوری شده است، به پیش‌بینی قیمت در این بازار پرداخته‌اند. آن‌ها برای این منظور از مدل‌های مختلف آماری و یادگیری ماشین بهره برده‌اند و با استفاده از یک سال مجموعه داده دوره آزمایش به مقایسه نتایج آن‌ها پرداخته‌اند. نتایج نشان می‌دهد که مدل‌های یادگیری عمیق مانند DNN و LSTM در مقایسه با سایر مدل‌های آماری و یادگیری ماشین عملکرد بهتری دارند. لازم به توضیح است که این مطالعه از الگوریتم بهینه‌سازی بیزی برای انتخاب هایپرپارامترها استفاده می‌کند.

اوگورلو و همکاران (۲۰۱۸) در مطالعه خود به پیش‌بینی قیمت‌های ساعتی در بازار روز بعد ترکیه پرداخته‌اند. داده‌های بازار برق مورد استفاده در این مطالعه بازه ۱ ژانویه ۲۰۱۳ تا ۲۱ دسامبر ۲۰۱۶ را شامل می‌شود. نویسندگان در مطالعه خود از مدل‌های مختلف آماری و یادگیری ماشین برای پیش‌بینی و

1. Artificial Neural Network (ANN)
2. Adaptive Neural Fuzzy Inference System (ANFIS)
3. Multivariate Linear Regression (MLR)
4. Support Vector Machine (SVM)
5. Random Forest (RF)
6. eXtreme Gradient Boosting (XGBoost)
7. Bayesian Additive Regression Trees (BART)
8. Recursive Feature Elimination (RFE)



مقایسه استفاده کرده‌اند. قابل ذکر است که وقفه‌های مورد استفاده در این مطالعه، چه برای مدل‌های آماری و چه یادگیری ماشین، با توابع خودهمبستگی^۱ و خودهمبستگی جزئی^۲ محاسبه شده‌اند. نتایج مطالعه یادشده نشان‌دهنده برتری مدل‌های یادگیری عمیق مانند DNN^۳ با MLP^۴ با بیش از یک لایه پنهان) و LSTM نسبت به مدل‌های آماری مانند تغییر رژیم مارکوف^۵ و SARIMA^۵ است. یافته‌های محققان با ادعای ورون (۲۰۱۴) مبنی بر عملکرد ضعیف مدل‌های تغییر رژیم مارکوف در پیش‌بینی قیمت‌های ساعتی، برخلاف عملکرد خوبشان در پیش‌بینی نوسانات و یا اوج‌های قیمتی، مطابقت دارد.

در حوزه مطالعات داخلی نیز معتمدی و همکاران (۱۳۹۷) با استفاده از داده‌های قیمت سال‌های ۱۳۹۵-۱۳۹۶ به پیش‌بینی قیمت تسویه در بازار برق بعد برق ایران پرداخته‌اند. نویسندگان در پژوهش خود پس از شناسایی هفت خوشه رقابتی برای بازار برق ایران، از الگوریتم ماشین بردار پشتیبان (SVM) برای پیش‌بینی استفاده کرده‌اند. محققان دقت ۹۶ و ۹۴ درصد را به ترتیب برای داده‌های سال‌های ۱۳۹۵ و ۱۳۹۶ گزارش کرده‌اند.

ممی‌پور و همکاران (۱۳۹۷) در مطالعه خود به پیش‌بینی نوسانات قیمت برق در بازار برق ایران با استفاده از مدل مارکوف سوئیچینگ گارچ^۶ پرداخته‌اند. مطالعه آن‌ها ۲۰۱۲ مشاهده داده قیمت برق با تواتر روزانه در بازه سال‌های ۱۳۹۲ تا ۱۳۹۷ را شامل می‌شود. نتایج نشان‌دهنده عملکرد بهتر مدل مارکوف سوئیچینگ گارچ در پیش‌بینی نوسانات قیمت در بازار برق ایران در مقایسه با سایر مدل‌های گارچ است.

ناظمی و همکاران (۱۳۹۷) با ترکیب شبکه عصبی فازی و الگوریتم بهینه ازدحام ذرات به پیش‌بینی قیمت در بازار برق ایران پرداخته‌اند. آن‌ها در مطالعه خود از داده‌های سال ۱۳۹۴ استفاده کرده‌اند. در این مطالعه از ضریب خودهمبستگی به منظور انتخاب مقادیر بهینه وقفه استفاده شده است. نتایج نشان‌دهنده برتری مدل یادشده در مقایسه با روش‌های ARIMA^۷، شبکه عصبی شعاعی پایه، شبکه عصبی فازی و ترکیب شبکه عصبی فازی با الگوریتم ژنتیک است.

منظور و یادی‌پور (۱۳۹۵) در مطالعه خود به کمک مدل‌های ARMAX^۸-GARCH به پیش‌بینی نوسانات قیمت در بازار برق ایران تنها با استفاده از داده‌های تاریخی قیمت برای سال‌های ۱۳۹۱-۱۳۹۳ پرداخته‌اند. نویسندگان بر این باور هستند که مدل پیشنهادی آن‌ها می‌تواند برای مدیریت ریسک در بازار برق مورد استفاده قرار بگیرد.

1. Auto-Correlation Function
2. Partial Auto-Correlation Function
3. Multi-Layer Perceptron (MLP)
4. Markov Regime-Switching
5. Seasonal Autoregressive Integrated Moving Average (SARIMA)
6. Markov Switching-GARCH
7. Autoregressive Integrated Moving Average (ARIMA)
8. Autoregressive Moving Average Model with eXogenous Inputs (ARMAX)



شایقی و قاسمی (۱۳۹۴) با استفاده از شبکه عصبی بهبودیافته مبتنی بر تبدیل موجک و روش آشوبناک جست‌وجوی گرانشی به پیش‌بینی قیمت روزانه برق در بازارهای برق اسپانیا و ایران پرداخته‌اند. آن‌ها در مطالعه خود از داده‌های ساعتی ۵۰ روزه در بازار اسپانیا و ۳۰ روزه در بازار ایران استفاده کرده‌اند. معیار میانگین درصد قدر مطلق خطا برای مدل پیشنهادی آن‌ها برابر با ۵/۱۳ است.

مروری بر مطالعات انجام‌شده در حوزه پیش‌بینی قیمت‌های برق نشان می‌دهد که تمرکز بخش عمده‌ای از آن‌ها که از روش‌های مبتنی بر یادگیری عمیق استفاده کرده‌اند، بازارهای خارج از ایران بوده است. هرچند در مطالعه حیدرپناه و همکاران (۲۰۲۳) از مدل یادگیری عمیق از نوع LSTM برای پیش‌بینی در بازار برق ایران استفاده شده است، اما مطالعه یادشده از تحلیل همبستگی ساده برای انتخاب مقادیر بهینه وقفه استفاده می‌کند؛ روشی که قادر به الگو کردن رفتار غیرخطی داده‌ها نیست. هم‌چنین فرآیند انتخاب هایپرپارامترها به‌عنوان عنصر مؤثر در عملکرد مدل در مطالعه آن‌ها نامشخص است. نکته حائز اهمیت دیگر آن است که همه مطالعاتی که به پیش‌بینی قیمت‌ها در بازار برق ایران می‌پردازند، از مشکل استفاده از داده‌های با اندازه نامناسب رنج می‌برند که این می‌تواند عملکرد مدل‌های یادگیری ماشین را تحت تأثیر قرار دهد. بر این اساس مطالعه پیش رو در راستای غلبه بر چالش‌های مزبور گام برمی‌دارد.

روش‌شناسی


بخش حاضر به تشریح روش‌شناسی مورد استفاده در پژوهش اختصاص دارد. در حالت کلی، در بازار روز بعد، پیشنهاد‌های برای ۲۴ ساعت از روز d ، قبل از یک موعد مقرر در روز $d - 1$ ارسال می‌گردد. این پیشنهاد‌های ساعتی است؛ به این معنا که هر فعال بازار ۲۴ پیشنهاد ارائه می‌دهد. پس از اتمام موعد مقرر، بهره‌بردار مستقل بازار با استفاده از پیشنهاد‌های ارائه‌شده، قیمت تسویه بازار را محاسبه می‌کند. بر این اساس یک مدل پیش‌بینی خوب باید قادر به پیش‌بینی ۲۴ قیمت تسویه بازار روز d ، پیش از اتمام موعد مقرر در روز $d - 1$ باشد.

۱. یادگیری عمیق

همان‌طور که در بخش مقدمه اشاره شد، مدل پایه یادگیری عمیق، DNN است. DNN حالت توسعه‌یافته پرسپترون‌های چندلایه است که بیش از یک لایه پنهان دارند. کمی پیچیده‌تر از DNN، RNNها هستند که به‌منظور حفظ اطلاعات گذشته، نگاشت‌های اضافی ایجاد می‌کنند؛ از این‌رو برای داده‌های سری زمانی مانند قیمت برق مناسب هستند. RNNهای پیشرفته برخلاف انواع استاندارد آن‌ها قادر به حل مشکل محوشدگی گرادیان‌ها هستند. یکی از انواع RNNهای پیشرفته، حافظه‌های طولانی کوتاه‌مدت (LSTM) است.

الف. شبکه‌های عصبی عمیق (DNN)

یک DNN با دو لایه پنهان در شکل (۱) نشان داده شده است. در این شکل، $X = [x_1, \dots, x_n]^T \in \mathbb{R}^n$ بردار ورودی شبکه، $Y = [y_1, \dots, y_m]^T \in \mathbb{R}^m$ بردار خروجی شبکه، n_k تعداد نورون‌ها در لایه پنهان k^{th} و $Z_k = [z_{k1}, \dots, z_{kn_k}]^T$ بردار حالت لایه پنهان k^{th} است.



شکل ۱. نمونه‌ای از یک شبکه عصبی عمیق

منبع: لاگو و همکاران (۱۸: ۲۰۱۸ الف)

یک نورون i در لایه k^{th} توسط رابطه (۱) معرفی می‌شود.


$$z_{ki} = f_{ki}(W_{ki}^T \cdot z_{k-1} + b_{ki}) \quad (۱)$$

در رابطه (۱)، f_{ki} تابع فعال‌سازی هر نورون، W_{ki}^T ماتریس وزن نگاشت‌ها از لایه $(k-1)^{th}$ به نورون i در لایه k^{th} و b_{ki} بایاس هر نورون است.

ب. حافظه‌های طولانی کوتاه‌مدت (LSTM)

برخلاف یک RNN استاندارد که هر نورون توسط یک واحد عصبی ساده و یا به عبارتی یک نگاشت غیرخطی واحد معرفی می‌شود، یک LSTM شامل یک سلول با چهار واحد عصبی به ازای هر نورون است. به کمک این چهار واحد عصبی، LSTM می‌تواند یک حالت سلول حافظه C با یک رفتار فراموشی-یادآوری انتخابی^۱ را مدل کند. به بیان دقیق‌تر، همان‌طور که در شکل (۲) نشان داده شده است، هر سلول LSTM شامل سه گیت است: گیت ورودی I ، گیت خروجی O و گیت فراموشی F . گیت‌های یادشده به همراه یک تابع تانژانت هائپربولیک، نشان‌دهنده چهار واحد عصبی هستند. یک سلول LSTM

در گام زمانی t شامل حالت پنهانی z_t ، حالت سلولی c_t و حالت ورودی x_t است. خروجی سلول نیز با حالت پنهانی z_t نشان داده می‌شود. در شکل (۲) دایره‌های آبی رنگ عملگرهای درایه‌ای و $\odot$ نماد ضرب درایه‌ای است.



شکل ۲. سلول پایه LSTM

منبع: لاگو و همکاران (۱۸: ۲۰۱۸ الف)

اساس کار هر سلول LSTM به این شرح است: در هر گام زمانی t ، نوروهای z_{t-1} و x_t را به‌عنوان متغیرهای تصمیم در نظر می‌گیرد و بر اساس آن‌ها گیت‌های F_t ، I_t و O_t را می‌سازد. از سه بردار اعداد حقیقی بین صفر و یک استفاده می‌کند. این بردارها انتخاب می‌کنند که کدام اطلاعات از z_{t-1} و c_{t-1} برای ساخت c_t و z_t استفاده شوند. با در نظر گرفتن پارامترهای یک سلول LSTM به‌عنوان ماتریس‌های $b_I, b_O, b_F, W_c, W_o, W_i, W_f$ ، نگاشت‌های عصبی شامل چهار مرحله است.

مرحله اول - گیت فراموشی تصمیم می‌گیرد تا کدام اطلاعات از حالت سلولی قبلی c_{t-1} در c_t حفظ شود. رابطه (۲) گیت فراموشی را نشان می‌دهد.

$$F_t = \sigma(W_F \begin{bmatrix} z_{t-1} \\ x_t \end{bmatrix} + b_F) \quad (2)$$

در رابطه (۲)، σ نشان‌دهنده تابع سیگموئید است.

مرحله دوم - گیت ورودی و واحد $\tanh$ تصمیم می‌گیرند که کدام اطلاعات جدید اضافه شوند. به بیان دقیق‌تر، واحد $\tanh$ یک بردار $\bar{c}_t$ با اطلاعات مرتبط جدید می‌سازد. این بردار در رابطه (۳) تعریف شده است.

$$\bar{c}_t = \tanh(W_c \begin{bmatrix} z_{t-1} \\ x_t \end{bmatrix} + b_c) \quad (3)$$

سپس گیت ورودی از طریق بردار (۴) ساخته می‌شود.



$$I_t = \sigma(W_I \begin{bmatrix} z_{t-1} \\ x_t \end{bmatrix} + b_I) \quad (4)$$

بردار رابطه (۴) انتخاب می کند که کدام اطلاعات جدید موجود در $\bar{c}_t$ ، در c_t حفظ گردد. مرحله سوم- با استفاده از F_t و I_t ، حالت سلولی جدید (۵) ساخته می شود.

$$c_t = F_t \odot c_{t-1} + I_t \odot \bar{c}_t \quad (5)$$

مرحله چهارم- در پایان گیت خروجی، آخرین بردار تصمیم گیری را می سازد. رابطه (۶) گیت خروجی را نشان می دهد.

$$O_t = \sigma(W_O \begin{bmatrix} z_{t-1} \\ x_t \end{bmatrix} + b_O) \quad (6)$$

گیت خروجی تصمیم می گیرد کدام اطلاعات c_t برای حالت پنهانی جدید z_t استفاده شود. رابطه (۷) این فرآیند را مشخص می کند.

$$z_t = O_t \odot \tanh(\bar{c}_t) \quad (7)$$

۲. الگوریتم انتخاب ویژگی XGBoost-RFE

قیمت برق تابع غیرخطی از مقادیر گذشته خود است؛ از این رو در اکثر مطالعات، مقادیر وقفه قیمت به عنوان ورودی منظور می شوند (پاناپاکیدیس و داگوماس، ۲۰۱۶). باید در نظر داشت که استفاده از تمامی مقادیر وقفه می تواند منجر به کاهش دقت مدل و افزایش پیچیدگی محاسبات شود. به منظور مقابله با این چالش از تکنیک های انتخاب ویژگی استفاده می شود (یاپراکدال و آریسوی، ۲۰۲۳؛ لی و بکر، ۲۰۲۱؛ گروگوتی و همکاران، ۲۰۱۶). در میان روش های مختلفی که برای انتخاب ویژگی وجود دارد، روش های پوشش^۵ به دلیل در نظر گرفتن روابط متقابل میان ویژگی ها و نیز نداشتن محدودیت در به کارگیری روش یادگیری، به روش های فیلتر و نهفته^۶ ترجیح داده می شوند (لاگو و همکاران، ۲۰۱۸ ب). حذف ویژگی بازگشتی (RFE)^۷ که اولین بار توسط گویان و همکاران (۲۰۰۲)^۸ معرفی شد، یک الگوریتم برای انتخاب ویژگی از خانواده روش های پوشش است که خود متضمن یک الگوریتم خاص دیگر

1. Panapakidis & Dagoumas
2. Yaprakdal & Arisoy
3. Li & Becker
4. Gregorutti *et al.*
5. Wrapper Methods
6. Embedded
7. Recursive Feature Elimination (RFE)
8. Guyon *et al.*



به‌منظور اجرای فرآیند انتخاب ویژگی است. پژوهش حاضر از $XGBoost^1$ که یک درخت تصمیم مبتنی بر تقویت گرادیان است و نخستین بار توسط چن و همکاران (۲۰۱۶)^۲ معرفی شده است، به‌عنوان یک الگوریتم یادگیری خارجی در RFE استفاده می‌کند. روش پیشنهادی که ابتدا با مجموعه تمام ویژگی‌ها شروع به کار می‌کند، شامل آموزش بازگشتی مدل، تخمین میزان اهمیت متغیرها با $XGBoost$ و حذف متغیرهای با کم‌ترین امتیاز است. برای تعیین آن‌که چه تعداد از ویژگی‌های موجود برای پیش‌بینی دقیق کافی است، از روش اعتبارسنجی متقابل K-Fold استفاده می‌شود. در این روش، داده‌های ورودی به K زیرمجموعه تقسیم می‌شوند. مدل بر روی $K-1$ زیرمجموعه آموزش داده می‌شود و نتایج را بر روی زیرمجموعه‌ای که آموزش داده نمی‌شود، اعتبارسنجی می‌کند. فرآیند یادشده، K بار بر روی زیرمجموعه‌های مختلف برای اعتبارسنجی تکرار می‌شود (یا پراکندال و آریسوی، ۲۰۲۳؛ مددخانی و ایکونیکووا، ۲۰۲۳؛ کاپور و ویکیتاکسورن، ۲۰۲۳^۳؛ زاهید و همکاران، ۲۰۱۹^۴).

۳. بهینه‌سازی هایپرپارامترها

یکی دیگر از مواردی که ممکن است منتج به عملکرد ضعیف مدل‌های یادگیری ماشین و یادگیری عمیق شود، تنظیمات نامناسب هایپرپارامترها است. برای غلبه بر این مشکل روش‌های بهینه‌سازی هایپرپارامتر مورد استفاده قرار می‌گیرد. در این راستا، الگوریتم بهینه‌سازی بیزی^۵ به سبب هزینه محاسباتی کم‌تر در مقایسه با جست‌وجوی شبکه‌ای^۶ و نیز امکان دستیابی به تنظیمات بهتر در مقایسه با جست‌وجوی تصادفی^۷ مورد توجه قرار می‌گیرد (هوانگ و همکاران، ۲۰۲۴).

اساس کار مدل یادشده، بهینه‌سازی یک تابع جعبه سیاه است؛ مانند عملکرد یک شبکه عصبی که تابعی از هایپرپارامترها است. مدل مذکور، مکرراً تقریبی از تابع جعبه سیاه را تخمین می‌زند و با استفاده از تقریب حداقل‌های محلی، در فضای تابع جست‌وجو می‌کند. در هر تکرار مشخص i ، الگوریتم، تابع جعبه سیاه را در یک نقطه جدید θ_i ارزیابی می‌کند. سپس تقریب $\mathcal{M}$ از تابع جعبه سیاه را از طریق برازش نقاط نمونه‌برداری شده قبلی روی ارزیابی‌های به‌دست‌آمده از تابع، تخمین می‌زند. در مرحله بعد، الگوریتم، نقطه نمونه بعدی θ_{i+1} را از طریق بهینه‌سازی عددی $\mathcal{M}$ انتخاب و تکرار بعدی را شروع می‌کند. در نهایت، پس از انجام حداکثر T تکرار، الگوریتم بهترین تنظیمات را انتخاب می‌کند (لاگو و همکاران، ۲۰۱۸^۸).

1. EXtreme Gradient Boosting (XGBoost)
2. Chen *et al.*
3. Kapoor & Wichitaksorn
4. Zahid *et al.*
5. Bayesian Optimization
6. Grid Search
7. Randm Search



تحلیل داده ها و نتایج تجربی

۱. نگاهی به واقعیت های آماری بازار برق ایران

در این بخش، اطلاعات آماری مرتبط با وضعیت تولید، مصرف و مبادلات در بازار برق ایران برای سال ۱۳۹۸ در قالب جدول (۱) ارائه شده است تا تصویری روشن از ابعاد کلان این بازار در بازه زمانی مدل سازی شده فراهم شود. دلیل انتخاب سال ۱۳۹۸ برای ارائه واقعیت های آماری بازار برق، هم راستایی آن با بازه زمانی داده های مورد استفاده در مدل سازی و پیش بینی قیمت برق در پژوهش حاضر است. بر اساس داده های جدول (۱)، انرژی مصرفی در شبکه بیش از انرژی تخصیص یافته از سوی تولیدکننده ها بوده است که بیانگر عدم تعادل در سطح شبکه است. همچنین، وجود معاملات خارج از بازار، با سهمی در حدود ۵ درصد از کل مبادلات، در کنار آزمون مصرف نسبتاً بالا، می تواند نشان دهنده وجود بخشی از مبادلات، خارج از مسیرهای رسمی بازار و نیز بروز ناپایداری هایی در رفتار مصرف باشد.

جدول ۱. واقعیت های آماری بازار برق ایران

عنوان	مقدار (بر حسب میلیون کیلووات ساعت)
انرژی تولیدی تخصیص داده شده (نقطه مرجع شبکه)	۳۰۶۹۵۸
انرژی مصرفی در نقطه مرجع شبکه	۳۰۹۰۰۴
اختلاف انرژی تولیدی تخصیص داده شده و انرژی مصرفی	-۲۰۴۶
انرژی مصرفی در محل مصرف	۳۰۷۰۴۱
معاملات خارج از بازار عمده فروشی برق	۱۷۵۶۵
آزمون مصرف خریداران	۱۵۶۵۶

منبع: معاونت بازار برق (۱۴۰۱)

۲. توصیف داده ها

مطالعه حاضر از داده های تاریخی قیمت تسویه در بازار برق ایران به منظور پیش بینی قیمت های روز بعد استفاده می کند. تواتر داده های یاد شده ساعتی است و بازه زمانی ۱ فروردین ۱۳۹۳ تا ۲۹ اسفند ۱۳۹۸ را شامل می شود. این اطلاعات از طریق انجام مکاتبات اداری با شرکت مدیریت شبکه برق ایران به دست آمده است. لازم به توضیح است که بخش اعظم این اطلاعات از طریق تارنمای بازار برق ایران^۱ قابل دسترسی است. جدول (۲) آمار توصیفی قیمت تسویه بازار برق ایران در بازه یاد شده را نشان می دهد.

جدول ۲. آمار توصیفی داده ها


تعداد مشاهدات	۵۲۵۸۴
کمینه	۱۳۸۰۰۲
بیشینه	۴۳۱۴۶۷
میانگین	۳۲۶۶۰۲/۵۵
انحراف معیار	۶۳۳۲۱/۳۰
چولگی	-۰/۱۸
کشیدگی	-۱/۲۰

منبع: یافته های پژوهش

بر اساس نتایج جدول (۲)، توزیع داده‌ها دارای کشیدگی کم‌تر از صفر است؛ به بیانی دیگر قله در توزیع داده‌ها پهن‌تر و پایین‌تر از حالت نرمال است. علاوه بر این معیار چولگی برای توزیع داده‌ها نیز منفی است که نشان‌دهنده چوله به چپ بودن توزیع داده‌ها است.

قیمت برق در ساعات مختلف روز دارای نوسانات قابل‌توجهی است. همان‌طور که در نمودار (۱) مشاهده می‌شود، وجود دو اوج قیمتی در ساعات نزدیک به ظهر (حدود ساعت ۱۱) و عصر (ساعت ۱۹) که ناشی از افزایش تقاضا در این ساعات است، مشهود است. همچنین قیمت‌ها در ساعات نیمه‌شب و اولیه صبح به کم‌ترین مقدار خود می‌رسد که ناشی از کاهش تقاضا در این بازه زمانی است.


نمودار (۲) نیز رفتار هفتگی قیمت در فصول مختلف سال را نشان می‌دهد. همان‌طور که قابل مشاهده است، قیمت‌ها علاوه بر نوسانات روزانه، دارای الگوی فصلی مشخصی نیز هست؛ به‌طوری‌که در فصل تابستان عمدتاً به علت افزایش تقاضای برق ناشی از مصرف سیستم‌های سرمایشی، قیمت برق به بالاترین مقدار خود در مقایسه با سایر فصول سال می‌رسند. نوسانات مشاهده‌شده در قیمت‌ها در هر دو نمودار، از یک‌سو بیانگر وجود رقابت اقتصادی در سمت عرضه و سازوکار بازارمحور قیمت‌گذاری در بازار برق عمده‌فروشی ایران است و از سوی دیگر، نشان‌دهنده پویایی و عدم تعادل پایدار در این بازار است.



نمودار ۱. رفتار قیمت‌ها در طول یک روز

منبع: یافته‌های پژوهش





نمودار ۲. رفتار قیمت‌ها در طول یک هفته انتخابی از هر فصل سال

منبع: یافته‌های پژوهش

۲. پیش‌پردازش داده‌ها

داده‌های مورد استفاده در این مطالعه دارای ۶ مقدار از دست‌رفته در دوم فروردین ماه هر سال به دلیل اجرای قانون تغییر ساعت رسمی (ساعت تابستانی) است که با استفاده از روش درون‌یابی^۱ مقادیر همسایه جایگزین شده‌اند. در مجموع مطالعه حاضر دارای ۵۲۵۸۴ مشاهده است. ۶۵ درصد از مشاهدات برای فرآیند آموزش، ۱۵ درصد برای اعتبارسنجی و ۲۰ درصد باقی‌مانده به منظور آزمون مورد استفاده قرار گرفته است. بازه زمانی داده‌های آموزش و اعتبارسنجی از ۱ فروردین ۱۳۹۳ تا ۱۹ دی ۱۳۹۷ را در برمی‌گیرد؛ درحالی‌که داده‌های مربوط به آزمون - که همان داده‌هایی هستند که پیش‌بینی روی آن‌ها انجام می‌شود - مربوط به بازه ۱۹ دی ۱۳۹۷ تا ۲۹ اسفند ۱۳۹۸ هستند. به دلیل محدوددهای متفاوت مقادیر داده‌ها، فرآیند آموزش با داده‌های نرمال‌شده انجام می‌شود. در صورتی‌که داده‌های مورد استفاده نرمال‌سازی نشوند، علاوه بر افزایش زمان آموزش، دقت عملکرد مدل کاهش می‌یابد. برای مدل‌های یادگیری ماشین و نیز یادگیری عمیق، داده‌ها به ترتیب در بازه $[0, 1]$ و $[-1, +1]$ نرمال می‌شوند. نرمال‌سازی در بازه دلخواه $[a, b]$ ، با استفاده از رابطه (۸) انجام می‌شود. در این رابطه P_r مقدار واقعی قیمت، $P_{\min}$ و $P_{\max}$ به ترتیب حداقل و حداکثر مقادیر قیمت واقعی و P قیمت استاندارد شده است (لاگو و همکاران، ۲۰۱۸؛ الف؛ هان و همکاران، ۲۰۱۲).

$$P = \frac{(P_r - P_{\min})}{(P_{\max} - P_{\min})} (b - a) + a \quad (8)$$

1. Interpolating
2. Han et al.

۳. برآورد و ارزیابی مدل‌ها

همان‌طور که پیش‌تر در باب اهمیت انتخاب ویژگی صحبت شد، عملکرد دقیق و مناسب مدل‌های یادگیری عمیق می‌تواند تحت تأثیر انتخاب مناسب ویژگی‌های ورودی قرار بگیرد. مطالعه حاضر از مقادیر وقفه قیمت‌های بازار برق ایران به‌عنوان ویژگی‌های ورودی استفاده می‌کند. با الگو گرفتن از مطالعات انجام‌شده در سطح بین‌الملل، پژوهش حاضر مقادیر وقفه تا یک هفته را به‌عنوان مجموعه اولیه ویژگی‌ها در نظر می‌گیرد. به بیان دقیق‌تر، از آنجاکه تواتر داده‌های مورد استفاده ساعتی است، با هدف پیش‌بینی قیمت‌ها برای ۲۴ ساعت روز بعد، مجموعه اولیه ویژگی‌ها $X_h = [P_{h-1}, P_{h-2}, P_{h-3}, \dots, P_{h-167}, P_{h-168}]$ شامل ۱۶۸ عضو است. به‌منظور انتخاب ویژگی‌های بهینه با تعداد مناسب، مطالعه حاضر از مدل XGBoost-RFE با روش اعتبارسنجی K-fold که در آن، $K = 5$ ، استفاده می‌کند. از آنجاکه مدل پیشنهادی نیازمند تنظیم فرایارامترها برای مدل یادگیری خارجی آن، یعنی XGBoost است، لذا تنظیم نامناسب فرایارامترها ممکن است منتج به انتخاب زیرمجموعه غیر بهینه از ویژگی‌ها شود؛ از این‌رو الگوریتم بهینه‌سازی بیزی که در بخش روش‌شناسی پیشنهاد شده، به‌منظور تنظیم مناسب فرایارامترهای مدل XGBoost مورد استفاده قرار می‌گیرد. جدول (۱) بخش پیوست، مجموعه‌های فضای هایپرپارامترها و هایپرپارامترهای انتخابی توسط الگوریتم بهینه‌سازی بیزی را نشان می‌دهد. پس از اجرای XGBoost-RFE، زیرمجموعه بهینه با ۱۳ عضو که جزئیات آن در جدول (۳) آمده است، توسط این الگوریتم انتخاب می‌گردد.

در گام بعد، هر کدام از مدل‌های یادگیری عمیق DNN و LSTM با استفاده از زیرمجموعه بهینه ویژگی‌ها برآورد می‌شوند. برآورد مدل یادگیری عمیق در مطالعه حاضر به فرآیند تخمین ماتریس وزن‌های W اشاره دارد. به بیانی دیگر با توجه به مجموعه آموزش $\mathcal{D}_T = \{(X_k, Y_k)\}_{k=1}^N$ که در آن $X_k = [x_1, \dots, x_n]^T \in \mathbb{R}^n$ بردار ورودی شبکه و $Y_k = [y_1, \dots, y_m]^T \in \mathbb{R}^m$ بردار خروجی شبکه است، آموزش با حل مسئله بهینه‌سازی عمومی (۹) و با N مشاهده داده انجام می‌شود.

$$\underset{W}{\text{minimize}} \quad \sum_{k=1}^N g_k(Y_k, F(X_k, W)) \quad (9)$$

در رابطه (۹)، $F: \mathbb{R}^n \rightarrow \mathbb{R}^m$ ، نگاشت شبکه عصبی و g_k تابع هزینه خاص مسئله است (لاگو و همکاران، ۲۰۱۸). از آنجاکه نحوه انتخاب هایپرپارامترها بر عملکرد دو مدل یادگیری عمیق پیشنهادی تأثیرگذار است، از الگوریتم بهینه‌سازی بیزی برای انتخاب هایپرپارامترهای آن‌ها استفاده می‌شود. نتایج اجرای این الگوریتم در جدول (۱) بخش پیوست نشان داده شده است. پس از آموزش هر یک از مدل‌ها، از معیار خطی میانگین درصد قدر مطلق خطا^۱ برای ارزیابی و مقایسه آن‌ها استفاده می‌شود. معیارهای خطی در مقایسه با معیارهای مبتنی بر خطاهای درجه دوم^۲، تفسیرپذیری آسان‌تری دارند. یکی از پرکاربردترین معیارهای خطی به‌منظور اندازه‌گیری دقت پیش‌بینی، معیار میانگین درصد قدر مطلق خطا است. این معیار با استفاده از رابطه (۱۰) محاسبه می‌شود (لاگو و همکاران، ۲۰۲۱).

1. Mean Absolute Percentage Error (MAPE)
2. Metrics Based on Quadratic Errors



$$MAPE = \frac{1}{24N_d} \sum_{d=1}^{N_d} \sum_{h=1}^{24} \frac{|p_{d,h} - \hat{p}_{d,h}|}{|p_{d,h}|} \quad (10)$$

در رابطه (۱۰)، $p_{d,h}$ و $\hat{p}_{d,h}$ به ترتیب قیمت های واقعی و پیش بینی شده در روز d و ساعت h و N_d تعداد روزهای مجموعه آزمایش است. نتایج ارزیابی مدل ها در جدول (۳) نشان داده شده است. مقایسه MAPE برای دو مدل پیشنهادی نشان دهنده برتری مدل LSTM نسبت به DNN است.

جدول ۳. مقایسه عملکرد مدل های پیشنهادی

MAPE	مدل پیش بینی	وقفه های بهینه انتخابی توسط مدل انتخاب ویژگی XGBoost-RFE
۱/۱۱	LSTM	$P_{h-1}, P_{h-2}, P_{h-23}, P_{h-24},$ $P_{h-25}, P_{h-26}, P_{h-47}, P_{h-48},$
۲/۱۹	DNN	$P_{h-50}, P_{h-71}, P_{h-72}, P_{h-74}, P_{h-167}$

منبع: یافته های پژوهش

۴. آزمون معناداری آماری

میانگین درصد قدر مطلق خطا (MAPE) معیاری است که از آن برای مقایسه دقت عملکرد مدل ها استفاده می شود. با این حال این حقیقت که دقت یک مدل از دیگری بالاتر است، تضمینی کافی برای بهتر بودن مدل نیست. به بیان دیگر، به منظور داشتن حداقل اطمینان از بهتر بودن یک مدل در مقایسه با دیگری، تفاوت در دقت عملکرد آن ها باید از نظر آماری نیز معنادار باشد. برای این منظور از نسخه یک طرفه آزمون آماری دیبولد-ماریانو^۱ که توسط دیبولد و ماریانو (۱۹۹۵)^۲ معرفی شده است، استفاده می شود.

با توجه به بردار سری زمانی $[y_1, \dots, y_N]^T$ که باید پیش بینی شود، دو مدل پیش بینی M_1 و M_2 و خطاهای پیش بینی مرتبط با آن ها، یعنی $[\varepsilon_1^{M_1}, \dots, \varepsilon_N^{M_1}]^T$ و $[\varepsilon_1^{M_2}, \dots, \varepsilon_N^{M_2}]^T$ ، آزمون دیبولد-ماریانو تفاوت معنادار در دقت عملکرد را بر اساس یک تابع هزینه خطا $L(\varepsilon_k^{M_i}) = |\varepsilon_k^{M_i}|$ بررسی می کند. به بیانی دیگر آزمون دیبولد-ماریانو تابع تفاضل زیان را به شکل رابطه (۱۱) ایجاد می کند.

$$d_k^{M_1, M_2} = L(\varepsilon_k^{M_1}) - L(\varepsilon_k^{M_2}) = |\varepsilon_k^{M_1}| - |\varepsilon_k^{M_2}| \quad (11)$$

با توجه به رابطه (۱۱)، آماره $DM = \sqrt{N}(\hat{\mu}/\hat{\sigma})$ است که در آن $\hat{\mu}$ و $\hat{\sigma}$ به ترتیب میانگین و انحراف معیار $d_k^{M_1, M_2}$ و N طول داده های آزمون است.

در نسخه یک طرفه، آزمون دیبولد-ماریانو فرضیه H_0 مبنی بر دقت برابر یا بیشتر مدل M_1 نسبت به مدل M_2 ، یا به بیانی دیگر زیان مورد انتظار برابر یا کوچک تر مدل M_1 نسبت به مدل M_2 را در برابر فرضیه جایگزین H_1 مبنی بر دقت بهتر مدل M_2 نسبت به مدل M_1 ارزیابی می کند. رابطه (۱۲) فرض های H_0 و H_1 این مدل را نشان می دهد.

1. Diebold- Mariano (DM) Test
2. Diebold & Mariano

$$\begin{cases} H_0: \mathbb{E}[d_k^{M_1, M_2}] \leq 0 \\ H_1: \mathbb{E}[d_k^{M_1, M_2}] > 0 \end{cases} \quad (12)$$


اگر فرضیه H_0 رد شود، آزمون، معناداری آماری برتری عملکرد مدل M_2 را نتیجه می‌گیرد. پس از انجام آزمون دیبولد-ماریانو، در صورتی که مقدار احتمال از سطح پذیرفته‌شده ۵ درصد کم‌تر باشد، فرضیه صفر رد می‌شود؛ این بدان معنا است که مدل دوم به‌صورت معناداری نسبت به مدل اول، پیش‌بینی دقیق‌تری دارد (لاگو و همکاران، ۲۰۲۱؛ لاگو و همکاران، ۲۰۱۸ الف). در مطالعه حاضر مدل اول DNN و مدل دوم LSTM در نظر گرفته شده است. نتایج آزمون در جدول (۴) قابل مشاهده است.

جدول ۴. آزمون دیبولد-ماریانو

آماره آزمون DM	احتمال	نتیجه آزمون
۴۲/۸۵	صفر	رد H_0

منبع: یافته‌های پژوهش

بنابراین از نظر آماری و بر اساس آزمون دیبولد-ماریانو، عملکرد دقیق‌تر مدل LSTM نسبت به DNN تأیید می‌گردد. نمودار (۳) عملکرد موفق مدل LSTM در پیش‌بینی قیمت‌های تسویه در بازار برق ایران را در مقایسه با قیمت‌های واقعی برای داده‌های مجموعه آزمایش نشان می‌دهد.



نمودار ۳. عملکرد پیش‌بینی مدل برتر پیشنهادی در پیش‌بینی قیمت‌ها در مقایسه با مقادیر واقعی

منبع: یافته‌های پژوهش



بحث، نتیجه‌گیری و جمع‌بندی

با آغاز تجدید ساختار و آزادسازی صنعت برق در جهان، پیش‌بینی دقیق قیمت‌های برق برای فعالان بازار برق اهمیت ویژه‌ای پیدا کرده است. دقت هرچه بیشتر یک مدل پیش‌بینی می‌تواند منجر به کاهش سطح ریسک، افزایش سود بنگاه‌ها و نیز پایداری سیستم قدرت شود. ایران از قاعده آزادسازی صنعت برق مستثنا نبوده است؛ از این رو دستیابی به یک پیش‌بینی دقیق برای فعالان بازار برق ایران حائز اهمیت است. در این راستا مطالعه حاضر با استفاده از داده‌های قیمت تسویه در بازار برق ایران و نیز با در نظر گرفتن الگوی رفتار غیرخطی داده‌ها، دو مدل ترکیبی مبتنی بر یادگیری عمیق به منظور پیش‌بینی قیمت ارائه و دقت عملکرد آن‌ها را با یکدیگر مقایسه کرده است. فارغ از مقایسه عملکرد، هریک از این دو مدل، به دلیل ماهیت ترکیبی آن‌ها، نسبت به مدل‌های پیش‌تر ارائه‌شده، به صورت مستقل نیز دارای جنبه‌های نوآورانه هستند. یکی از وجوه متمایز و نوآورانه این پژوهش آن است که برخلاف مطالعات پیشین که از روش‌های خطی برای انتخاب ویژگی و تعیین مقادیر بهینه وقفه قیمت بهره برده‌اند، مطالعه حاضر رفتار غیرخطی داده‌های بازار برق ایران را در فرآیند انتخاب ویژگی مدل ترکیبی لحاظ کرده است. علاوه بر این، پژوهش حاضر به منظور تنظیم بهینه‌های پارامترهای مدل‌ها، از الگوریتم بهینه‌سازی متفاوتی نسبت به مطالعات پیشین در زمینه پیش‌بینی قیمت در بازار برق ایران استفاده کرده است. در نهایت، با هدف غلبه بر چالش محدودیت داده‌ها در مطالعات قبلی پیش‌بینی قیمت در بازار برق ایران، این پژوهش از مجموعه داده‌ای با اندازه مناسب استفاده کرده است؛ به گونه‌ای که دوره آزمایش آن بیش از یک سال را در بر می‌گیرد. مقایسه MAPE دو مدل ترکیبی ارائه‌شده، برتری مدل XGBoost-RFECV-LSTM نسبت به XGBoost-RFECV-DNN را نشان می‌دهد. آزمون آماری دیبولد-ماریانو نیز این برتری را تأیید می‌کند. این تفاوت در عملکرد به قابلیت مدل مبتنی بر LSTM در حفظ وابستگی‌های زمانی و شناسایی روندهای قیمتی در بازار برق بازمی‌گردد که به دلیل وجود سلول‌های حافظه در ساختار آن امکان‌پذیر شده است. یادآور می‌گردد مدل‌های پیشنهادی بسیار تحت تأثیر انتخاب بهینه ویژگی‌های ورودی و تنظیمات مناسب‌های پارامترها هستند. از این رو، علی‌رغم عملکرد بسیار خوب مدل برتر پیشنهادی، امکان بهبود آن در مطالعات بعدی با توسعه دسترسی به منابع اطلاعاتی و محاسباتی گسترده‌تر وجود دارد.

ملاحظات اخلاقی

حامی مالی: مقاله حامی مالی ندارد.

مشارکت نویسندگان: تمام نویسندگان در آماده سازی مقاله مشارکت داشتند.

تعارض منافع: بنا بر اظهار نویسندگان در این مقاله هیچگونه تعارض منافی وجود ندارد.

تعهد کپی رایت: طبق تعهد نویسندگان حق کپی رایت رعایت شده است.



منابع

- ابونوری، ا. سمعیل و لاجوردی، ح. سن. (۱۳۹۲). تاثیر تشکیل بازار برق ایران بر کارایی نیروگاه های برق. کیفیت و بهره‌وری در صنعت برق/ ایران، ۲(۳)، ۵۷-۵۰.
- بازار برق ایران. (بدون تاریخ). تجارت برق. وبسایت بازار برق ایران. بازیابی‌شده در ۲۷ فروردین ۱۴۰۴، از <https://www.irema.ir>
- دفتر مطالعات اقتصادی و توسعه بازار برق. (۱۳۹۳). سازوکار فعالیت در بازار عمده‌فروشی برق ایران (گردآورندگان: ایمان رحمتی، جعفر خیاط‌زاده، اشرف خسروی، بیتا حسین‌زاده). شرکت مدیریت شبکه برق ایران.
- شایقی، ح. سین و قاسمی، علی. (۱۳۹۴). پیش‌بینی قیمت روزانه برق با شبکه عصبی بهبودیافته مبتنی بر تبدیل موجک و روش آشوبناک جستجوی گرانشی. مجله مهندسی برق دانشگاه تبریز، ۴(۴)، ۱۱۳-۱۰۳.
- معاونت بازار برق. (۱۴۰۱). پایش و تحلیل بازار برق ایران از سال ۱۳۹۸ تا ۱۴۰۰. بیتا حسین‌زاده، محمد حیدری‌زاده، اشرف خسروی، جعفر خیاط‌زاده، نرجس رهقان، ایمان رحمتی، مریم طاهری، سید میثم عزتی، ح. سن غریب‌پور، ح. سین محمدی و عبداللهی‌نیا (گردآورندگان). شرکت مدیریت شبکه برق ایران.
- معمودی سده، امید؛ استادی، بختیار و حسین زاده کاشان، علی. (۱۳۹۷). پیش‌بینی قیمت تسویه در بازار برق: الگوریتم ماشین بردار پشتیبان بهبودیافته. پژوهش‌های سیاه سنگداری و برنامه‌ریزی انرژی، ۴(۱۱)، ۳۴-۷.
- ممی پور، سیاب؛ منصوری، فهیمه و ناظمی، علی. (۱۳۹۷). پیش‌بینی نوسانات قیمت برق در بازار برق ایران با استفاده از مدل مارکوف سوئیچینگ گارچ. مدل‌سازی اقتصادسنجی، ۳(۲)، ۹۳-۱۲۲.
- منظور، داوود و یادی پور، مهدی. (۱۳۹۵). ارزیابی و پیش‌بینی نوسانات قیمت در بازار برق ایران به کمک مدل ARMAX-GARCH. اقتصاد مقداری، ۱۳(۱)، ۹۷-۱۱۷.
- ناظمی، علی؛ ممی پور، سیاب و رحیمی، سلمان. (۱۳۹۷). پیش‌بینی قیمت برق با تاکید بر جهش های قیمت با استفاده از ترکیب شبکه عصبی-فازی با الگوریتم بهینه ازدحام ذرات. نشریه مهندسی صنایع، ۵۲(۲)، ۲۷۷-۲۹۰.

References

- Abounoori, E; & Lajevardi, H. (2013). To Asses the Impact of Establishment of Iran's Electric Power Market On Efficiency of Power Plants. *Iranian Electric Industry Journal of Quality and Productivity*, 2(3), 50-57. (In Persian).
- Aggarwal, S. K; Saini, L. M; & Kumar, A. (2009). Electricity price forecasting in deregulated markets: A review and evaluation. *International Journal of Electrical Power and Energy Systems*, 31(1), 13-22.
- Amjadi, N; & Hemmati, M. (2006). Energy price forecasting-problems and proposals for such predictions. *IEEE Power and Energy Magazine*, 4(2), 20-29.



- Chen, T; & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 13-17-August-2016*, 785–794.
- Costa, A. B. R; Ferreira, P. C. G; Gaglianone, W. P; Guillén, O. T. C; Issler, J. V; & Lin, Y. (2021). Machine learning and oil price point and density forecasting. *Energy Economics*, 102.
- Diebold, F. X; & Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business and Economic Statistics*, 13(3), 253–263.
- Gregorutti, B; Michel, B; & Saint-Pierre, P. (2017). Correlation and variable importance in random forests. *Statistics and Computing*, 27(3), 659–678.
- Guyon, I; Weston, J; & Barnhill, S. (2002). *Gene Selection for Cancer Classification using Support Vector Machines* (Vol. 46).
- Han, J; Kamber, M; & Pei, J. (2012). *Data Mining: Concepts and Techniques* (Third Edition). Elsevier.
- Heidarpanah, M; Hooshyaripor, F; & Fazeli, M. (2023). Daily electricity price forecasting using artificial intelligence models in the Iranian electricity market. *Energy*, 263.
- Huang, S; Shi, J; Wang, B; An, N; Li, L; Hou, X; ... & Zhong, M. (2024). A hybrid framework for day-ahead electricity spot-price forecasting: A case study in China. *Applied Energy*, 373, 123863.
- Iran Electricity Market. (n.d.). *Electricity trading*. Iran Power Market website. Retrieved April 15, 2025, from <https://www.irema.ir>
- Jedrzejewski, A; Lago, J; Marcjasz, G; & Weron, R. (2022). Electricity Price Forecasting: The Dawn of Machine Learning. *IEEE Power and Energy Magazine*, 20(3), 24–31.
- Kapoor, G; & Wichitaksorn, N. (2023). Electricity price forecasting in New Zealand: A comparative analysis of statistical and machine learning models with feature selection. *Applied Energy*, 347, 121446.
- Keles, D; Scelle, J; Paraschiv, F; & Fichtner, W. (2016). Extended forecast methods for day-ahead electricity spot prices applying artificial neural networks. *Applied Energy*, 162, 218–230.
- Kirschen, D. S; & Strbac, G. (2018). *Fundamentals of power system economics*. John Wiley & Sons.
- Lago, J; de Ridder, F; & de Schutter, B. (2018a). Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. *Applied Energy*, 221, 386–405.
- Lago, J; de Ridder, F; Vrancx, P; & de Schutter, B. (2018b). Forecasting day-ahead electricity prices in Europe: The importance of considering market integration. *Applied Energy*, 211, 890–903.
- Lago, J; Marcjasz, G; de Schutter, B; & Weron, R. (2021). Forecasting day-ahead electricity prices: A review of state-of-the-art algorithms, best practices and an open-access benchmark. In *Applied Energy* (Vol. 293). Elsevier Ltd.
- Li, W; & Becker, D. M. (2021). Day-ahead electricity price prediction applying hybrid models of LSTM-based deep learning methods and feature selection algorithms under consideration of market coupling. *Energy*, 237.

Madadkhani, S; & Ikonnikova, S. (2024). Toward high-resolution projection of electricity prices: A machine learning approach to quantifying the effects of high fuel and CO2 prices. *Energy Economics*, 129.

Mamipour, S; Mansouri, F; & Nazemi, A. (2018). Multi-objective Modeling of Industrial Clusters from the Perspective of Dynamic Cellular Manufacturing Systems and Sustainable Economic Development. *The Journal of Econometric Modelling*, 3(2), 93–122. (In Persian).

Manzor, D; & Yadipour, M. (2016). Studying the Iranian Electricity Market Price with an ARMAX-GARCH Model. *Quarterly Journal of Quantitative Economics*, 13(1), 97–117. (In Persian).

Morales, J. M; Conejo, A. J; Madsen, H; Pinson, P; & Zugno, M. (2014). *Integrating Renewables in Electricity Markets* (Vol. 205). Springer US.

Motamedi, O; Ostadi, B; & Husseinazadeh Kashan, A. (2018). Prediction Model for Iran's Electricity Market Clearing Prices: Improved SVM Algorithm. *Quarterly Journal of Energy Policy and Planning Research*, 4(11), 7–34. (In Persian).

Nazemi, A; Mamipour, S; & Rahimi, S. (2018). Forecasting Price of Electricity Emphasizing Prices Jumps Using Combination of Neural and Fuzzy Network with Particle Swarm Optimization. *Advances in Industrial Engineering*, 52(2), 277–290. (In Persian).

Nielsen, S; Sorknaes, P; & Østergaard, P. A. (2011). Electricity market auction settings in a future Danish electricity system with a high penetration of renewable energy sources - A comparison of marginal pricing and pay-as-bid. *Energy*, 36(7), 4434–4444.

Office for Economic Studies and Electricity Market Development. (2014). *Mechanism of operation in Iran's wholesale electricity market* (Compiled by I. Rahmati, J. Khayyatzadeh, A. Khosravi, & B. Hoseinzadeh). Iran Grid Management Company.

Panapakidis, I. P; & Dagoumas, A. S. (2016). Day-ahead electricity price forecasting via the application of artificial neural network based models. *Applied Energy*, 172, 132–151.

Power Market Department. (2022). *Monitoring and analysis of Iran's electricity market from 2019 to 2021* (Compiled by B. Hoseinzadeh, M. Heydarizadeh, A. Khosravi, J. Khayyatzadeh, N. Rahghan, I. Rahmati, M. Taheri, S. M. Ezzati, H. Gharibpour, H. Mohammadi, & A. Abdollahinia). Iran Grid Management Company.

Saleh, A. M; István, V; Khan, M. A; Waseem, M; & Ali Ahmed, A. N. (2024). Power system stability in the Era of energy Transition: Importance, Opportunities, Challenges, and future directions. *Energy Conversion and Management: X*, 24, 100820.

Shahidehpour, M; Yamin, H; & Li, Z. (2002). *Market operations in electric power systems: forecasting, scheduling, and risk management*. John Wiley & Sons.

Shayeghi, H; & Ghasemi, A. (2015). Day-Ahead Electricity Price Forecasting Using WT, ANN and Chaotic Gravitational Search Model. *Tabriz Journal of Electrical Eng*, 45(4), 103–113. (In Persian).

Shuai, M; Chengzhi, W; Shiwen, Y; Hao, G; Jufang, Y; & Hui, H. (2018). Review on Economic Loss Assessment of Power Outages. *Procedia Computer Science*, 130, 1158–1163.



Ugurlu, U; Oksuz, I; & Tas, O. (2018). Electricity price forecasting using recurrent neural networks. *Energies*, 11(5), 1255.

United Nations. (2015). Transforming our world: The 2030 agenda for sustainable development.

Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. In *International Journal of Forecasting* (Vol. 30, Issue 4, pp. 1030–1081). Elsevier B.V.

Yaprakdal, F; & Varol Arisoy, M. (2023). A Multivariate Time Series Analysis of Electrical Load Forecasting Based on a Hybrid Feature Selection Approach and Explainable Deep Learning. *Applied Sciences (Switzerland)*, 13(23).

Zahid, M; Ahmed, F; Javaid, N; Abbasi, R. A; Zainab Kazmi, H. S; Javaid, A; ... & Ilahi, M. (2019). Electricity price and load forecasting using enhanced convolutional neural network and enhanced support vector regression in smart grids. *Electronics*, 8(2), 122.

Zhang, X; Wang, J; & Gao, Y. (2019). A hybrid short-term electricity price forecasting framework: Cuckoo search-based feature selection with singular spectrum analysis and SVM. *Energy Economics*, 81, 899–913.

COPYRIGHTS



This license allows others to download the works and share them with others as long as they credit them, but they can't change them in any way or use them commercially.

Table 1. Hyperparameter space sets for all models

Model	Hyperparameter Space Sets	Optimum Values
XGBoost	Number of estimators: range(100, 1000, 50)	550
	Learning Rate: [0.001, 0.01, 0.1, 1]	0.1
	Max Depth: range(4, 10, 2)	4
	Mean Child Weight: [4, 5]	4
	Colsample by Tree: range(0.4, 1, 0.2)	0.6
	Subsample: range(0.5, 1, 0.25)	0.5
	Eta: range(0.3, 0.9, 0.1)	0.5
	Max evals :500	500
DNN	Hidden Layer: [2, 3]	2
	Node in L1: [16, 32, 64, 128]	16
	Node in L2: [16, 32, 64, 128]	128
	Learning Rate: [1e-01, 1e-02, 1e-03, 1e-04, 1e-05]	1e-02
	Batch Size: [8, 16, 32, 64]	16
	Optimizer: [Adam, Nadam]	Adam
	Activation: Selu	Selu
	Epochs: 200	200
LSTM	Hidden Layer: [1, 2, 3]	2
	Node in L1: [16, 32, 64, 128]	64
	Node in L2: [16, 32, 64, 128]	128
	Learning Rate: [1e-01, 1e-02, 1e-03, 1e-04, 1e-05]	1e-04
	Batch Size: [8, 16, 32, 64]	8
	Optimizer: [Adam, Nadam]	Nadam
	Activation: Selu	Selu
	Epochs: 100	100

