

فصلنامه پژوهش‌های سیاستگذاری و برنامه‌ریزی انرژی

سال چهارم / شماره ۱۱ / تابستان ۱۳۹۷ / صفحات ۳۴-۷

پیش‌بینی قیمت تسویه در بازار برق: الگوریتم ماشین بردار پشتیبان بهبود یافته

امید معتمدی

دانشجوی دکترا، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس

omid.motamedi@modares.ac.ir

بختیار استادی

استادیار دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس

(نویسنده مسئول)

bostadi@modares.ac.ir

علی حسین‌زاده کاشان

استادیار، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس

a.kashan@modares.ac.ir

با تشکیل بازار برق ایران در سال ۱۳۸۲، تولیدکنندگان انرژی با ثبت پیشنهاد قیمت خود به صورت روزانه در سامانه مدیریت شبکه، با یکدیگر به رقابت می‌پردازند. در این رقابت تنها تولیدکنندگانی پیروز هستند که قیمت پیشنهادی آنها پایین‌تر از قیمت تسویه بازار در ساعات روز بعد باشد. از این رو، پیش‌بینی قیمت تسویه بازار در روز بعد برای تولیدکنندگان انرژی امری حیاتی بوده و در کسب هر چه بیشتر سهم بازار برق ایران به صورت روزانه توسط آنها تاثیرگذار است. در این مطالعه، با ترکیب الگوریتم K-means و ماشین بردار پشتیبان، مدل جدیدی جهت پیش‌بینی قیمت تسویه بازار در روز بعد ارائه شده است. مطابق با نتایج حاصل از پیاده‌سازی مدل پیشنهادی بر روی داده‌های سال‌های ۱۳۹۵ و ۱۳۹۶، هفت خوشه رقابتی برای بازار برق ایران شناسایی شده که متوسط دقت مدل پیشنهادی در پیش‌بینی قیمت تسویه بازار در هر یک از این خوشه‌ها برای سال‌های ۱۳۹۵ و ۱۳۹۶ به ترتیب برابر با ۹۶ و ۹۴ درصد می‌باشد.

واژه‌های کلیدی: ماشین بردار پشتیبان، خوشه‌بندی، پیش‌بینی قیمت تسویه بازار، بازار برق ایران

تاریخ پذیرش: ۱۳۹۷/۳/۸

تاریخ دریافت: ۱۳۹۷/۲/۲۵

۱. مقدمه

با مقررات زدایی از صنعت برق و واگذاری نیروگاه‌ها به بخش خصوصی با اهداف جذب سرمایه بخش خصوصی، افزایش بهره‌وری، شفاف‌سازی پارامترهای هزینه و کاهش تصدی‌گری دولت، بازار روز فروش انرژی جهت رقابت تولیدکنندگان انرژی شکل گرفت.

همانند سایر کالاها، در این بازار تمامی تولیدکنندگان انرژی با ارائه پیشنهاد قیمت برای میزان تولید خود در روز بعد، با یکدیگر به رقابت می‌پردازند. اما وجود تفاوت‌های اساسی میان برق و سایر کالاها، منجر به تفاوت در نحوه مبادلات این کالا شده است. از جمله تفاوت‌های برق با سایر کالاها می‌توان موارد ذیل را نام برد:

۱. ذخیره‌سازی برق بسیار هزینه‌بر و در ابعاد بالا غیرممکن است، لذا این کالا باید به محض تولید، مصرف شود. (ساندها و همکاران، ۲۰۱۶)


۲. نظر به استراتژیک بودن این کالا، همواره توان تولیدی (جمع آمادگی تمامی تولیدکنندگان) از میزان تقاضا بیشتر خواهد بود و همواره افزونگی عرضه وجود دارد. (خسروی و همکاران، ۲۰۱۳)

از این رو، بازار انرژی به منظور مبادله این کالا شکل گرفته است. به طور کلی، بازار انرژی به دو گروه تسویه تک‌مرحله‌ای و تسویه دو مرحله‌ای تقسیم می‌شود. در بازار تک‌مرحله‌ای، انرژی عرضه‌شده در همان روز و همان ساعت مبادله می‌شود، اما در بازار دو مرحله‌ای که به بازار روز بعد نیز معروف است، انرژی موردنیاز در هر لحظه، یک روز قبل تر خریداری می‌شود. (ساندها و همکاران، ۲۰۱۶)

در بازار روز بعد، دو روش پرداخت به نام‌های پرداخت بر اساس قیمت بازار و پرداخت بر اساس قیمت پیشنهادی وجود دارد که در حالت پرداخت بر اساس قیمت بازار، فرایند تسویه با تمامی تولیدکنندگان در روز بعد با قیمت ثابت و برابر با قیمت تسویه بازار (بیشترین قیمت پذیرفته‌شده) انجام

می‌گیرد در حالی که در بازارهای با سازوکار پرداخت بر اساس پیشنهاد قیمت، پیشنهاد قیمت هر یک از تولیدکنندگان مبنای پرداخت آن تولیدکننده واقع می‌شود. (گریل، ۲۰۱۰)

در ایران نیز فرایند مقررات زدایی از بازار انرژی در سال ۱۳۸۲ با نوشتن آیین‌نامه بازار برق و به دنبال آن خصوصی‌سازی نیروگاه‌ها آغاز شد. در بازار رقابتی ایران که به صورت بازار یک روز بعد است، در هر روز میزان تقاضای ساعتی برای روز بعد توسط مدیریت شبکه اعلام می‌گردد. به دنبال آن، تمامی تولیدکنندگان انرژی، توان تولیدی خود در روز بعد را به همراه قیمت پیشنهادی خود (حداکثر در ۱۰ پله)، تا ساعت ۱۰ صبح در سامانه مدیریت شبکه ثبت می‌نمایند. سپس طی محاسبات انجام‌شده در سامانه مدیریت شبکه، نتایج پیشنهاد قیمت (تولیدکنندگان برنده) در ساعت ۱۹ همان روز اعلام خواهد شد. مبنای محاسبات مدیریت شبکه تامین تقاضای روز بعد با حداقل هزینه است که بدین منظور ابتدا تمامی پله‌های پیشنهادی تولیدکنندگان از کوچک به بزرگ مرتب شده و تقاضای موردنیاز از محل پایین‌ترین قیمت‌ها برآورده می‌شود. (یوسفی و همکاران، ۲۰۱۷) (مطابق با شکل ۱)



شکل ۱. تعیین قیمت تسویه بازار در بازار روز فروش انرژی ایران

بعد از تعیین قیمت بازار، فرایند تسویه حساب با تولیدکنندگان بر مبنای قیمت پیشنهادی آنها انجام می‌شود. مبلغ پرداختی به تولیدکنندگان در بازار روز بعد ایران، از دو قسمت تولید و آمادگی تشکیل می‌شود که با در نظر گرفتن واحد ppg از نیروگاه pp در ساعت h میزان مبلغ پرداختی برای تولید

آن نیروگاه بر اساس قیمت پیشنهادی آن واحد انجام می‌گیرد و مبلغ پرداختی بابت آمادگی آن واحد از معادله (۱) محاسبه می‌شود. (هیئت تنظیم بازار، ۱۳۸۴)

$$Paymentant_AV_{pp,ppg,h} = A_{pp,ppg,h} + B_{pp,ppg,h} - C_{pp,ppg,h} \quad (۱)$$

که در آن، پارامترها از معادلات ذیل محاسبه می‌شوند.

$$A_{pp,ppg,h} = \max \left\{ \left[\left(p_Dec_{pp,ppg,h} - \frac{E - Co_{pp,ppg,h}}{1 - \%L_G_{pp,h}} \right) \times CPA_h \times BAR \right], 0 \right\} \quad (۲)$$

$$B_{pp,ppg,h} = X_FOG_{pp,ppg,h} \times \max \left\{ \left[\left(E_TGU_{pp,ppg,h} - (P_S_{pp,ppg,h} \times (1 - \rho_IC_{pp,ppg,h})) \right) \right], 0 \right\} \quad (۳)$$

$$C_{pp,ppg,h} = X_FOG_{pp,ppg,h} \times \max \left\{ \left[\left(\min \left(\frac{E_TGU_{pp,ppg,h} \cdot p_Dec_{pp,ppg,h}}{Avcap_Max_{pp,ppg,h} \times (1 - \rho_IC_{pp,ppg,h})} \right), \left(P_S_{pp,ppg,h} \times (1 - \rho_I_{pp,ppg,h}) \right) \right) \right], 0 \right\} \quad (۴)$$

که در آن، پارامترها به ترتیب عبارت‌اند از:

$Paymentant_AV_{pp,ppg,h}$: بهای پرداختی بابت خالص آمادگی واحد ppg م نیروگاه pp در ساعت

ساعت h ام

$p_Dec_{pp,ppg,h}$: میزان خالص ظرفیت ابراز شده واحد ppg م نیروگاه pp در ساعت h ام

$E - Co_{pp,ppg,h}$: میزان ظرفیت تخصیص داده شده به واحد ppg م نیروگاه pp در ساعت h ام

بابت تعهدات خارج از بازار روز فروش

$E_TGU_{pp,ppg,h}$: میزان انرژی خالص تولید شده واحد ppg م نیروگاه pp در کل ساعت h ام

$P_S_{pp,ppg,h}$: قدرت عملی پردازش شده نهایی ناخالص ساعتی واحد ppg م نیروگاه pp در

ساعت h ام

$Avccap_Max_{pp,ppg,h}$: میزان سقف مجاز ابراز آمادگی برای واحد ppg ام نیروگاه pp در

ساعت h ام

$L_G_{pp,h} \%$: درصد تلفات انتقال انرژی از نیروگاه pp تا نقطه مرجع شبکه در ساعت h ام که

برای هر نیروگاه توسط مدیر بازار اعلام می‌شود.

$\rho_IC_{pp,ppg,h}$: درصد مصرف داخلی واحد ppg ام نیروگاه pp ام که مورد تأیید کارشناس

منتخب هیئت تنظیم بازار برق می‌باشد.

CPF_h : ضریب بهای آمادگی ظرفیت در ساعت h ام

BAR : نرخ پایه بهای آمادگی ظرفیت که در هر سال توسط هیئت تنظیم بازار برق تعیین می‌شود.

$X_FOG_{pp,ppg,h}$: برای واحدهای دارای سیستم خنک‌کن از تاریخ ۱۵ خرداد تا ۱۵ شهریور برابر

با ۱ و در سایر موارد برابر صفر محاسبه می‌شود.

با توجه به تابع پرداختی از سوی مدیریت شبکه، همواره تولیدکنندگان تمایل دارند با ارائه پله‌های قیمتی بهینه (نزدیک به قیمت تسویه بازار)، سود خود را بیشینه کنند، اما در مطالعات قیمت‌دهی، پیشنهادها در بازار روز بعد و به دنبال آن قیمت تسویه بازار در روز بعد همواره عامل‌های غیرقطعی می‌باشند که منجر به پیچیده شدن مساله می‌شود. در این شرایط، اگر تولیدکننده‌ای قیمت‌پذیر باشد، از آنجا که قیمت تسویه بازار (با فرض کامل بودن بازار) مستقل از استراتژی انتخابی تولیدکننده است، به جای تخمین تعداد زیادی پارامتر غیرقطعی، پارامتر قیمت تسویه بازار را به عنوان تنها پارامتر غیرقطعی تخمین می‌زند. از این رو، پیش‌بینی صحیح قیمت تسویه بازار در روز بعد، به طور مستقیم بر سود بخشی تولیدکنندگان انرژی تأثیر می‌گذارد. (یوسفی و همکاران، ۲۰۱۷)

نظر به اهمیت قیمت تسویه در بازار برق، روند تغییرات آن در طول روز و در مقاطع مختلف سال و تأثیر مستقیم آن بر درآمد تولیدکنندگان انرژی، پیش‌بینی آن برای تمامی تولیدکنندگان امری ضروری است. از این رو، در پاسخ به این سؤال که آیا امکان پیش‌بینی قیمت تسویه در بازار روز بعد انرژی با

دقت بالا وجود دارد یا خیر، در این مطالعه بعد از شناسایی و خوشه‌بندی سطح رقابت در طول سال در بازار برق ایران، مدل جدیدی جهت پیش‌بینی قیمت تسویه بازار ارائه شده است.

در مدل پیشنهادی، از الگوریتم ماشین بردار پشتیبان بهبود یافته با استفاده از الگوریتم K-means جهت پیش‌بینی قیمت تسویه بازار در روز بعد استفاده شده است، به گونه‌ای که ابتدا فضای رقابتی بازار برق در ایران به خوشه‌های رقابتی متفاوت تقسیم شده و برای هر خوشه با استفاده از الگوریتم ماشین بردار پشتیبان، پیش‌بینی قیمت تسویه بازار به صورت مجزا انجام گرفته است. از این رو، نوآوری‌های ارائه شده در این مطالعه عبارت‌اند از: خوشه‌بندی فضای رقابتی بازار برق ایران با استفاده از الگوریتم K-means و پیش‌بینی قیمت تسویه بازار در خوشه‌های رقابتی به صورت مجزا با استفاده از ماشین برداری پشتیبان.

در ادامه این تحقیق، بعد از ارائه پیشینه تحقیق در بخش بعدی، در بخش سوم، مبانی نظری تحقیق به همراه مدل پیشنهادی ارائه شده است؛ در بخش چهارم، نتایج حاصل از پیاده‌سازی مدل پیشنهادی در دنیای واقعی آورده شده است و در نهایت، در بخش پنجم، نتیجه‌گیری ارائه شده است.

۲. پیشینه تحقیق

تاکنون روش‌های متفاوتی برای پیش‌بینی قیمت تسویه بازار در بازار برق ارائه شده است مانند: مدل سری زمانی^۱ (نوگالس و همکاران، ۲۰۱۳)، مدل گارچ^۲ (ژانگ و همکاران، ۲۰۱۲)، ترکیب مدل میانگین متحرک خودهمبسته^۳ با تبدیل موجک^۴ (یانگ و همکاران، ۲۰۱۷)، مدل سری زمانی خودهمبسته با استفاده از منطق فازی^۵ (خاشعی و همکاران، ۲۰۱۳)، الگوریتم K نزدیک‌ترین همسایه

-
1. Time Series
 2. Garch
 3. Autoregressive Moving Average
 4. Wavelet Transform
 5. Fuzzy Logic

(لورا و همکاران، ۲۰۰۷)، ترکیب مدل رگرسیون چندمتغیره^۱ و مدل تبدیل موجک (نوگالس و کنجو، ۲۰۰۶)، نظریه بازی‌ها^۲ (امین و همکاران، ۲۰۱۲؛ لوپرته و هوبس، ۲۰۱۶؛ کی و همکاران، ۲۰۱۷)، بهینه‌سازی بیزین^۳ (لاگو و همکاران، ۲۰۱۸)، ترکیب مدل ماشین بردار پشتیبان^۴ و رگرسیون خطی^۵ (ساینی و همکاران، ۲۰۱۶؛ ژائو و همکاران، ۲۰۰۷)، ترکیب شبکه عصبی^۶ با الگوریتم‌های ازدحام ذرات^۷ و الگوریتم ژنتیک^۸ (ژیو و همکاران، ۲۰۱۳)، الگوریتم ازدحام ذرات فازی (قدیمی و همکاران، ۲۰۱۳)، زنجیره مارکوف^۹ (گنزالز و همکاران، ۲۰۰۵)، مدل شبکه عصبی (قلی پور و همکاران، ۲۰۱۸؛ لین و همکاران، ۲۰۱۰؛ پاناپاکیدیس و داگونماس، ۲۰۱۶)، مدل شبکه عصبی فازی (امجدی، ۲۰۰۶؛ کاتالو و همکاران، ۲۰۱۱)، ترکیب شبکه عصبی با الگوریتم فراابتکاری خفاش^{۱۰} (بنتو و همکاران، ۲۰۱۸)، ترکیب شبکه عصبی با تبدیل موجک (لاهمیری، ۲۰۱۴)، ترکیب شبکه عصبی با الگوریتم امداد^{۱۱} (امجدی و همکاران، ۲۰۱۰).

مطابق با مقاله ارائه‌شده توسط ورون در سال ۲۰۱۴، مزیت‌ها و معایب ذیل را می‌توان برای مدل‌های مختلف پیش‌بینی قیمت تسویه بازار برشمرد. (ورون، ۲۰۱۴)

1. Multi Variable Regression
2. Game Theory
3. Bayesian Optimization
4. Support Vector Machin
5. Linear Regression
6. Neural Network
7. Particle Swarm Optimization
8. Genetic Algorithm
9. Markov Chain
10. Bat Optimization
11. Relief Algorithm

جدول ۱. مقایسه روش‌های پیش‌بینی قیمت تسویه بازار

روش	مزایا	معایب
الگوریتم‌های فراابتکاری	اشتراک‌گذاری اطلاعات، سرعت همگرایی بالا، استفاده از حافظه	امکان گرفتار شدن در بهینه محلی، ارائه جواب‌های متفاوت در اجراهای متفاوت
شبکه عصبی	دقت بالا	زمان‌بر بودن، نیاز به حجم بالای داده آموزشی، تفسیرپذیری پایین
نزدیک‌ترین همسایه	عدم نیاز به فرض اولیه	یادگیرنده تنبل، وابستگی به پارامتر k
ماشین بردار پشتیبان	سراسری، تفسیرپذیری و انعطاف‌پذیری بالا	وابستگی به نوع تابع کرنل انتخاب‌شده، نیاز به حافظه بالا جهت محاسبه بهینه‌سازی کوادراتیک

از بین مدل‌های ارائه‌شده، اخیراً روش ماشین‌بردار پشتیبان به عنوان یک روش یادگیری بر مبنای کمینه‌سازی ریسک ساختاری، مورد توجه محققان جهت پیش‌بینی قیمت تسویه بازار قرار گرفته است. (یان و چوداری، ۲۰۱۴)

در این روش، برخلاف شبکه عصبی که در آن پیدا کردن یک رابطه پیچیده میان متغیرهای ورودی دنبال می‌شود، ابتدا داده‌ها به یک فضای اقلیدسی با ابعاد بالاتر نگاشت شده و با استفاده از یک تابع ساده رابطه میان مقادیر ورودی و خروجی در فضای جدید تعیین می‌گردد و برخلاف شبکه عصبی که با ارائه حداقل‌های محلی به عنوان جواب با جواب‌های متفاوتی مواجه هستیم، در این روش، با ارائه جواب کمینه سراسری، همواره با یک جواب یکتا مواجه خواهیم بود و از سوی دیگر، نسبت به سایر روش‌های فراابتکاری، روش ماشین‌بردار پشتیبان ساده‌تر و انعطاف‌پذیرتر می‌باشد. (ساینی و همکاران، ۲۰۱۶)

مطابق با مقایسه صورت گرفته توسط سانسوم و همکاران در سال ۲۰۰۲ میان الگوریتم ماشین‌بردار پشتیبان و الگوریتم بهینه‌سازی خطی با استفاده از داده‌های یکسان برای هر دو مدل، الگوریتم

ماشین بردار پشتیبان نسبت به مدل بهینه‌سازی خطی در پیش‌بینی قیمت تسویه بازار با زمان حل پایین‌تر، از دقت بالاتری برخوردار است. (سانسوم و همکاران، ۲۰۰۲)

در سال ۲۰۱۰، چه و وانگ با ترکیب دو مدل ماشین بردار پشتیبان و میانگین متحرک خودهمبسته، مدل جدیدی تحت عنوان SVRARIMA جهت پیش‌بینی قیمت تسویه بازار ارائه نمودند که مطابق با نتایج بدست آمده، مدل ارائه‌شده عملکرد بهتری نسبت به مدل شبکه عصبی و میانگین متحرک خودهمبسته ساده دارد. در مطالعه‌ای مشابه در سال ۲۰۱۳، چان و چوداری با ترکیب دو الگوریتم ماشین بردار پشتیبان و مدل میانگین متحرک خودهمبسته با مقادیر خارجی^۱ به پیش‌بینی قیمت تسویه بازار پرداختند.

به دنبال آن، در مطالعه سلیمان و همکاران در سال ۲۰۱۲ الگوریتم ماشین بردار پشتیبان با الگوریتم کلونی زنبور^۲ به منظور پیش‌بینی قیمت تسویه بازار در بازار برق ترکیب شده، به گونه‌ای که الگوریتم کلونی زنبور به عنوان تنظیم‌کننده پارامترهای الگوریتم ماشین بردار پشتیبان در نظر گرفته شده است. مطابق با نتایج بدست آمده، مدل ارائه‌شده نسبت به مدل ماشین بردار پشتیبان و الگوریتم زنبور عملکرد بهتری دارد.

نیو و همکاران در سال ۲۰۱۰ با ترکیب دو الگوریتم نقشه خودسازمان‌دهنده^۳ و ماشین بردار پشتیبان به پیش‌بینی قیمت تسویه بازار پرداختند. در این مدل ابتدا داده‌ها بر اساس میزان قیمت با استفاده از الگوریتم نقشه‌های خودسازمان‌دهنده خوشه‌بندی شده و سپس با استفاده از الگوریتم ماشین بردار پشتیبان برای هر خوشه پیش‌بینی به صورت مجزا صورت گرفته است.

در مطالعه‌ای مشابه توسط چان و چوداری در سال ۲۰۱۴، با ترکیب دو الگوریتم ماشین بردار پشتیبان به صورت سری به پیش‌بینی قیمت تسویه بازار پرداخته شده است. در مدل ارائه‌شده در این مقاله، ابتدا

1. Auto-regressive Moving Average with External Input
2. Bee Colony Algorithm
3. Self-organizing Map

داده‌ها با استفاده از الگوریتم ماشین‌بردار پشتیبان اول بر اساس سطح قیمت، به چهار گروه قیمت پایین، قیمت متوسط، قیمت بالا و قیمت پیک تقسیم شده و با استفاده از الگوریتم ماشین‌بردار پشتیبان برای هر گروه از داده‌ها به صورت مجزا پیش‌بینی صورت گرفته است.

مشابه با دو مطالعه آخر، در این مطالعه ابتدا داده‌های موردبررسی با استفاده از الگوریتم K-means خوشه‌بندی شده و به دنبال آن، با استفاده از الگوریتم ماشین‌بردار پشتیبان، قیمت تسویه بازار در هر خوشه پیش‌بینی شده است.

۳. مبانی نظری

در مدل پیشنهادی، از ترکیب دو الگوریتم K-means و ماشین‌بردار پشتیبان به منظور پیش‌بینی قیمت تسویه بازار در روز بعد استفاده شده است. در این مدل، به علت رفتار فصلی شدید قیمت تسویه بازار، ابتدا با استفاده از الگوریتم K-means خوشه‌بندی رقابتی به گونه‌ای انجام شده است که روزهای سال در خوشه‌های همسان قرار گرفته و برای پیش‌بینی قیمت تسویه در هرروز، با استفاده از الگوریتم ماشین‌بردار پشتیبان، تنها از رکوردهای موجود در خوشه مربوط به آن روز استفاده شده است. این امر منجر به حذف داده‌های پرت در فرایند ساخت ماشین‌بردار پشتیبان می‌شود و مطابق با نتایج حاصل، دقت مدل به صورت چشم‌گیری افزایش یافته است.

الگوریتم K-means

الگوریتم K-means به منظور خوشه‌بندی داده‌ها استفاده می‌شود که با استفاده از آن به یافتن یک ساختار درون یک مجموعه از داده‌های بدون برجسب پرداخته می‌شود. خوشه به مجموعه‌ای از داده‌ها گفته می‌شود که به هم شباهت داشته باشند و در خوشه‌بندی سعی می‌شود تا داده‌ها به خوشه‌هایی تقسیم شوند که شباهت بین داده‌های درون هر خوشه حداکثر و شباهت بین داده‌های درون خوشه‌های متفاوت حداقل شود. (موک، ۲۰۰۸)

- الگوریتم K-means شامل تکرار چهار مرحله ذیل است. (موک، ۲۰۰۸)
۱. ابتدا به صورت تصادفی K مرکز خوشه ایجاد می‌گردد.
 ۲. فاصله تمام رکوردها از تمامی K مرکز خوشه اندازه‌گیری می‌شود و هر رکورد به نزدیک‌ترین خوشه تخصیص داده می‌شود.
 ۳. بعد از محاسبه میانگین مقادیر موجود در هر خوشه، مراکز قبلی هر خوشه با مقدار میانگین اعضای آن خوشه، جایگزین می‌شود.
 ۴. در نهایت، شرط توقف الگوریتم بررسی و در صورت برقراری آن، الگوریتم متوقف می‌شود و در صورت عدم برقراری آن، به گام ۲ رفته و با تکرار گام‌های ۲ و ۳ الگوریتم ادامه می‌یابد.
- از آنجایی که در الگوریتم K-means تعداد خوشه‌ها به صورت دستی مشخص می‌شود، با استفاده از شاخص دیویس بولدین^۱ می‌توان تعداد خوشه‌های بهینه را به گونه‌ای تعیین نمود که بیشترین شباهت درون‌خوشه‌ای و کمترین شباهت بین‌خوشه‌ای حاصل شود.
- بدین منظور، با در نظر گرفتن n_c به‌عنوان تعداد خوشه و V_i به‌عنوان مرکز آمین خوشه، c_i به‌عنوان تعداد رکوردهای موجود در خوشه i ام و X_{ij} به‌عنوان i امین رکورد در خوشه i ام، شباهت میان دو خوشه i و k از رابطه (۵) محاسبه می‌شود. (موک، ۲۰۰۸)

$$R_{i,k} = \frac{\sum_{j=1}^{c_i} d(x_{ij}, v_i) + \sum_{j=1}^{c_k} d(x_{ij}, v_k)}{d(v_i, v_k)} \quad (5)$$

که در آن، d بیانگر تابع فاصله بر مبنای فاصله اقلیدسی است. با در نظر گرفتن میزان شباهت میان دو خوشه مطابق با رابطه (۵)، شاخص دیویس بولدین از رابطه (۶) محاسبه می‌گردد.

$$DB = \frac{\sum_{i=1}^{n_c} R_i}{n_c} \quad (6)$$

1. Davies Bouldin Index

که در آن، R_i از رابطه زیر محاسبه می‌گردد.

$$R_i = \text{MAX} (R_{i,1}, R_{i,2}, \dots, R_{i,i-1}, R_{i,i+1}, \dots, R_{i,n_c}) \quad \forall i = 1, 2, \dots, n_c \quad (7)$$

بدین منظور، برای حالات ۲، ۳ و ... خوشه، الگوریتم K-means به صورت مجزا حل می‌گردد و مقدار شاخص دیویس بولدین برای هر یک از حالات محاسبه می‌شود. در نهایت، حالتی که مقدار شاخص دیویس بولدین برای آن کمتر از سایر حالات گردد، به عنوان حالت بهینه در نظر گرفته می‌شود.

الگوریتم ماشین بردار پشتیبان

این الگوریتم را نخستین بار محقق به نام فیشر در سال ۱۹۶۳ باهدف کاهش خطای طبقه‌بندی داده‌های آموزشی ارائه نمود. در مدل ماشین بردار پشتیبان، تابعی مرتب با متغیر وابسته y که خود تابعی از چند متغیر مستقل x است، برآورد می‌شود. مشابه سایر مسائل رگرسیونی، در این روش فرض می‌شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به علاوه مقداری اغتشاش (خطای مجاز) مطابق با رابطه (۸) مشخص شود. (ساینی و همکاران، ۲۰۱۶)

$$f(x) = W^T \cdot \varphi(x) + b \quad (8)$$

$$y = f(x) + \text{noise} \quad (9)$$

چنانچه W بردار ضرایب و b ثابت * مشخصه‌های تابع رگرسیونی و φ نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای $f(x)$ است که با واسنجی مدل ماشین بردار پشتیبان به وسیله مجموعه‌ای از نمونه‌ها (مجموعه واسنجی) محقق می‌شود. این روند شامل بهینه‌سازی متوالی خطا مطابق با رابطه (۱۰) و با در نظر گرفتن محدودیت‌های (۱۱) تا (۱۳) می‌باشد.

$$\min \frac{1}{2} W^T W + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* \lambda_i, \lambda_i^* \quad (10)$$

$$-y_i + W^T \cdot \varphi(x) + b \geq \varepsilon + \varepsilon_i^* \quad (11)$$

$$y_i - W^T \cdot \varphi(x) - b \leq \varepsilon + \varepsilon_i \quad (12)$$

$$\varepsilon_i, \varepsilon_i^* \geq 0, i \in N \quad (13)$$

در معادلات بالا، C عددی صحیح و مثبت است که عامل تعیین جریمه در هنگام رخ دادن خطای واسنجی مدل است. φ تابع کرنل N تعداد نمونه‌ها و دو مشخصه $\varepsilon_i, \varepsilon_i^*$ متغیرهای کمبود هستند که حد بالا و پایین خطای آموزش مرتب با مقدار خطای مجاز را مشخص می‌کنند. (سایینی و همکاران، ۲۰۱۶)

در مساله بهینه‌سازی فوق با معرفی ضرایب لاگرانژ λ_i, λ_i^* تابع هدف مساله بهینه‌سازی به رابطه (۱۴) با در نظر گرفتن محدودیت‌های (۱۵) تا (۱۷) تغییر می‌یابد.

$$\sum_{i=1}^N y_i (\lambda_i - \lambda_i^*) - \varepsilon \sum_{i=1}^N (\lambda_i + \lambda_i^*) - 0.5 \sum_{i=1}^N \sum_{j=1}^N (\lambda_i - \lambda_i^*) (\lambda_j - \lambda_j^*) \varphi(x_i)^T \varphi(x_j) \quad (14)$$

$$\sum_{i=1}^N (\lambda_i + \lambda_i^*) = 0 \quad (15)$$

$$0 \leq \lambda_i \leq C \quad (16)$$

$$0 \leq \lambda_i^* \leq C \quad (17)$$

تابع هدف رابطه (۱۴) تابع محدب است. بنابراین، جواب رابطه (۱۴) یکتا و بهینه خواهد بود. پس از تعریف ضرایب لاگرانژ در رابطه (۱۴) مشخصه‌های w و b در مدل ماشین بردار پشتیبان رگرسیونی با استفاده از شرایط نظریه کرانش - کوهن - تاکر محاسبه می‌شود. در نتیجه، برای مقادیر W خواهیم داشت:

$$W = \sum_{i=1}^N (\lambda_i + \lambda_i^*) \cdot \varphi(x_i)^T \cdot \varphi(x_i) \cdot b \quad (18)$$

باید توجه داشت که مقادیر ضرایب لاگرائز می‌تواند صفر و یا غیر صفر باشد. بنابراین، فقط مجموعه داده‌هایی که ضرایب آنها غیر صفر است، در معادل رگرسیون نهایی وارد می‌شوند. این مجموعه داده‌ها به عنوان بردارهای پشتیبان شناخته می‌شوند. به‌طور ساده، بردارهای پشتیبان، آن داده‌هایی هستند که به ساختار شدن تابع رگرسیونی کمک می‌کنند. در میان بردارهای یادشده، آنهایی که مقدار لاگرائز آنها کمتر از C باشد، بردارهای پشتیبان حاشیه‌ای نامیده می‌شوند و در صورت برابری مقدار لاگرائز با مقدار C، به عنوان بردار پشتیبان خطا یا بردار پشتیبان کران‌دار شناخته می‌شود. بردارهای پشتیبان حاشیه‌ای در حاشیه مرز غیرحساس یافت می‌شوند درحالی‌که بردارهای پشتیبان خطا خارج از بازه‌اند. درنهایت، تابع رگرسیونی را می‌توان به شکل رابطه (۱۹) بازنویسی کرد.

$$f(X) = \sum_{i=1}^N \bar{\lambda}_i \cdot \varphi(x_i)^T \cdot \varphi(x) + b \quad (19)$$

که در آن، مقدار $\bar{\lambda}_i$ برابر با میانگین ضرایب لاگرائز است.


۴. پیاده‌سازی مدل پیشنهادی

بازار برق ایران با ظرفیت نامی نصب‌شده معادل با ۷۳۷۵۸ مگاوات و متوسط مصرف ۳۱۳۲۲ مگاوات ساعت انرژی که ۳۲ درصد آن مصرف خانگی، ۳۴ درصد آن مصرف صنعتی و مابقی آن مصرف کشاورزی و عمومی است، به فعالیت خود ادامه می‌دهد. مطابق با آمار منتشرشده، ۴۴ درصد از ظرفیت نامی نصب‌شده در اختیار بخش خصوصی بوده که روزانه در کنار بخش دولتی پیشنهاد قیمت خود را برای پله‌های انرژی به مدیریت شبکه ارائه خواهد داد. (یوسفی و همکاران، ۲۰۱۷)

در این بازار، تمامی تولیدکنندگان انرژی، صرف‌نظر از دولتی یا خصوصی بودن، با ارائه پیشنهاد قیمت در ۱۰ پله غیرنزولی برای هر ساعت از روز بعد به تفکیک واحدهای تحت تملک، با یکدیگر به رقابت می‌پردازند. بعد از ثبت قیمت‌های پیشنهادی در سامانه مدیریت شبکه، مدیریت شبکه با

لحاظ کردن محدودیت‌های شبکه و در نظر گرفتن سطح تقاضای برآوردشده در هر ساعت از روز بعد، محل تامین تقاضا را با حداقل هزینه مشخص می‌کند و برندگان را اعلام می‌نماید.

شکل (۲) بیانگر قیمت‌های موزون پیشنهادی در هر یک از ۲۴ ساعت از روزهای سال ۱۳۹۵ می‌باشد که مطابق با آنچه از روند تقاضا انتظار می‌رفت، بیشترین قیمت در فصول گرم سال و کمترین قیمت‌های تسویه در فصول سرد سال مشاهده می‌شود.



شکل ۲. متوسط قیمت موزون در هر یک از ساعات ایام سال ۱۳۹۵


نظر به تفاوت شدید در میزان تقاضای انرژی در ساعات یک روز و همچنین تغییر الگوی مصرف با تغییر دما و تغییرات فصل، قیمت تسویه بازار از نوسانات شدید در طول زمان برخوردار است و از الگوهای فصلی پیروی می‌کند (یوسفی و همکاران، ۲۰۱۷). لذا قبل از پیاده‌سازی مدل پیش‌بینی قیمت تسویه بازار بر روی داده‌های واقعی، ابتدا با استفاده از الگوریتم K-means، روزهای سال از منظر حجم تقاضا خوشه‌بندی شده است که مطابق با بکارگیری این الگوریتم بر روی داده‌های سال ۱۳۹۵ و با استفاده از شاخص دیویس بولدین در کل سه روند دوره‌ای در بازار برق ایران حاکم است. این سه روند در حقیقت، نشان‌دهنده زمان اوج مصرف، زمان مصرف کم و زمان گذار از هر یک از این دوره‌ها به دیگری می‌باشند. (مطابق جدول ۲)

جدول ۲. خوشه‌های تقسیم تقاضا در طول سال ۱۳۹۳

خوشه ۱	خوشه ۲	خوشه ۳
۲۵ روز اول فروردین	۵ روز آخر فروردین	۱۰ روز آخر خرداد
۱۰ روز آخر مهر	اردیبهشت	تیر
آبان	۲۰ روز اول خرداد	مرداد
آذر	۲۰ روز اول مهر	شهریور
دی		
بهمن		
اسفند		

خوشه اول از ۱۰ روز آخر مهرماه شروع شده و تا ۲۵ روز اول فروردین ماه سال بعد ادامه خواهد داشت. در این دوره، به علت کاهش دما در عموم شهرهای کشور، میزان تقاضا برای کالای برق کاهش می‌یابد و به دنبال آن، قیمت تسویه بازار در پایین‌ترین نقطه خود قرار دارد. ویژگی‌های اصلی این خوشه که فصول سرد سال را شامل می‌شود، سطح پایین تقاضا و پایین بودن تغییرات در میزان تقاضا می‌باشد. لذا در این خوشه انتظار می‌رود معاملات در سطوح میانی قیمت و نزدیک به قیمت تمام‌شده انجام پذیرد.


شکل (۳) بیانگر روند قیمت تسویه بازار در یک روز از روزهای مربوط به خوشه ۱ می‌باشد.



شکل ۳. متوسط موزون قیمت تسویه بازار (هزار ریال) در ساعات روز ۹۵/۰۹/۲۳

با اجرای دوباره الگوریتم خوشه‌بندی K-means برای رکوردهای این خوشه می‌توان ساعات مربوط به روزهای این خوشه را در دو خوشه مجزا تقسیم نمود، به گونه‌ای که خوشه اول شامل ساعت ۹ شب تا ۸ صبح بوده و خوشه دوم شامل سایر ساعات روز باشد. خوشه دوم از ۲۵ فروردین تا ۲۰ خرداد را شامل می‌شود که در این زمان با افزایش دما به مرور افزایش تقاضا و به دنبال آن، نوسانات در قیمت تسویه بازار را شاهد هستیم. از سوی دیگر، این خوشه شامل ۲۰ روز اول مهرماه نیز می‌باشد که بیان‌کننده دوره کاهش تقاضا (با حرکت از فصول گرم به فصول سرد) است. به عبارت دیگر، خوشه ۲ بیانگر زمان گذر از خوشه ۱ به خوشه ۳ می‌باشد و برعکس.

شکل (۴) بیانگر روند نوسانات قیمت تسویه بازار در روز ۹۵/۰۲/۱۹ از این خوشه می‌باشد.




شکل ۴. متوسط موزون قیمت تسویه بازار (هزار ریال) در ساعات روز ۹۵/۰۲/۱۹

با بکارگیری دوباره الگوریتم K-means به منظور خوشه‌بندی ساعات مربوط به روزهای این خوشه، نتیجه برابر با سه خوشه خواهد شد که اولین خوشه شامل ساعات ۱۱ شب تا ۷ صبح، خوشه دوم شامل ساعات ۸ صبح تا ۱۰ صبح و ساعات ۵ عصر تا ۸ عصر و سومین خوشه نیز شامل ساعات ۱۱ صبح تا ساعت ۴ عصر و ساعات ۹ و ۱۰ شب است.

خوشه سوم شامل ۱۰ روز انتهایی خردادماه و کل فصل تابستان است که در این دوره با افزایش دما، تقاضا بشدت افزایش یافته و به دنبال آن، قیمت تسویه بازار بالا می‌رود. در این خوشه، قیمت در بالاترین سطح خود قرار دارد و کمترین نوسانات را در میزان قیمت و تقاضا شاهد هستیم. خوشه ۳ بیانگر گرم‌ترین روزهای سال می‌باشد که بیشترین تقاضا سالانه در روزهای این خوشه اتفاق می‌افتد. با بالا رفتن حجم تقاضا در روزهای این خوشه، قیمت‌های پیشنهادی تولیدکنندگان نیز به بالاترین سطح خود می‌رسد، به گونه‌ای که در این خوشه، در ۹۶ درصد موارد، قیمت تسویه بازار در دهک بالایی سقف قیمت قرار می‌گیرد.

شکل (۵) بیانگر روند قیمت تسویه بازار در ساعات روز ۹۵/۰۵/۰۹ از این خوشه می‌باشد.



شکل ۵. متوسط موزون قیمت تسویه بازار (هزار ریال) در ساعات روز ۹۵/۰۵/۰۹

با استفاده مجدد از الگوریتم K-means جهت خوشه‌بندی ساعات روزهای مربوط به خوشه سوم، دو خوشه حاصل خواهد شد که خوشه اول از ساعت ۲ بامداد تا ساعت ۸ صبح را شامل می‌شود و خوشه دوم شامل سایر ساعات روز می‌باشد.


مطابق با نتایج تحقیق‌یافته در بررسی بازار برق ایران، در مجموع، ۷ الگوی قیمتی در طول یک سال به شرح زیر شناسایی شده است:

خوشه ۱: از ساعت ۹ شب تا ۸ صبح از ۱۰ روز آخر مهرماه تا ۲۵ فروردین ماه
خوشه ۲: از ساعت ۹ صبح تا ۸ شب از ۱۰ روز آخر مهرماه تا ۲۵ فروردین ماه
خوشه ۳: از ساعت ۱۱ شب تا ۷ صبح از روزهای مربوط به ۲۵ فروردین تا ۲۰ خرداد
خوشه ۴: از ساعت ۸ صبح تا ۱۰ صبح و ۵ عصر تا ۸ شب در روزهای ۲۵ فروردین تا ۲۰ خرداد
خوشه ۵: از ساعت ۱۱ صبح تا ۴ عصر و ساعت ۹ شب و ۱۰ شب در روزهای میان ۲۵ فروردین ماه تا ۲۰ خرداد


خوشه ۶: از ساعت ۲ بامداد تا ۸ صبح در ۱۰ روز انتهایی خردادماه و کل فصل تابستان

خوشه ۷: از ساعت ۹ صبح تا ۱ بامداد در ۱۰ روز انتهایی خردادماه و کل فصل تابستان


به منظور اجرای الگوریتم ماشین بردار پشتیبان جهت پیش‌بینی قیمت تسویه بازار در هر یک از خوشه‌های فوق‌الذکر، داده‌های هر خوشه به دو قسمت جهت ساخت مدل و آزمودن مدل تقسیم گردیده که ۹۰ درصد از رکوردهای هر خوشه در قسمت ساخت و ۱۰ درصد از داده‌ها در قسمت آزمودن قرار داده شده است. با اجرای مدل ماشین بردار پشتیبان برای هر یک از خوشه‌های فوق‌الذکر، نتیجه به صورت شکل‌های (۶) تا (۱۲) به دست آمده است.




شکل ۶. نتیجه مدل پیش‌بینی قیمت تسویه بازار در خوشه زمانی اول




شکل ۷. نتیجه مدل پیش‌بینی قیمت تسویه بازار در خوشه زمانی دوم




شکل ۸. نتیجه مدل پیش‌بینی قیمت تسویه بازار در خوشه زمانی سوم




شکل ۹. نتیجه مدل پیش‌بینی قیمت تسویه بازار در خوشه زمانی چهارم



شکل ۱۰. نتیجه مدل پیش‌بینی قیمت تسویه بازار در خوشه زمانی پنجم



شکل ۱۱. نتیجه مدل پیش‌بینی قیمت تسویه بازار در خوشه زمانی ششم



شکل ۱۲. نتیجه مدل پیش‌بینی قیمت تسویه بازار در خوشه زمانی هفتم

نظر به نتایج حاصل از اجرای مدل پیشنهادی برای خوشه‌های رقابتی در مقایسه با مدل ماشین بردار پشتیبان بدون در نظر گرفتن خوشه‌های رقابتی، نتایج دو مدل بر اساس پارامتر MSAE با معادله زیر مقایسه شده‌اند.

$$MASE_{T,M} = \frac{1}{T} \sum_{h=1}^T \frac{|y_h - \hat{y}_h|}{\frac{1}{T-m} \sum_{h=m+1}^T |y_h - \hat{y}_{h-m}|} \quad (20)$$

که نتایج حاصل از مقایسه آن دو، مطابق با جدول (۳) است.

جدول ۳. مقایسه مدل پیشنهادی و مدل ماشین بردار پشتیبان ساده در سال ۱۳۹۵

خوشه	مدل پیشنهادی	مدل ماشین بردار پشتیبان
خوشه ۱	۴,۱٪	۶,۳٪
خوشه ۲	۵,۳٪	۵,۹٪
خوشه ۳	۲,۹٪	۸,۲٪
خوشه ۴	۶,۱٪	۱۲,۵٪
خوشه ۵	۱,۸٪	۸,۳٪
خوشه ۶	۲,۴٪	۶,۵٪
خوشه ۷	۲,۱٪	۴,۹٪

ماخذ: یافته‌های تحقیق

مطابق با نتایج جدول (۳)، مدل پیشنهادی بر روی داده‌های سال ۱۳۹۵ نسبت به مدل ماشین بردار پشتیبان ساده، از عملکرد بهتری برخوردار است، به گونه‌ای که مدل پیشنهادی در بعضی از روزهای سال با دقت ۹۸ درصد قادر به پیش‌بینی قیمت تسویه بازار در روز بعد می‌باشد و در بدترین حالت که مربوط به روزهای با نوسانات قیمت بالا می‌باشد، مدل پیشنهادی با متوسط دقت ۹۳/۸ درصد قیمت تسویه بازار را پیش‌بینی نموده است.

به منظور بررسی دقیق‌تر مدل پیشنهادی، مدل ارائه شده برای داده‌های سال ۱۳۹۶ پیاده‌سازی شده است و نتایج بدست آمده حاصل از اجرای مدل برای هر یک از خوشه‌های رقابتی مطابق با جدول (۴) می‌باشد.

جدول ۴. مقایسه مدل پیشنهادی و مدل ماشین بردار

پشتیبان ساده در سال ۱۳۹۶

خوشه	مدل پیشنهادی	مدل ماشین بردار پشتیبان
خوشه ۱	۵,۴٪	۷,۲٪
خوشه ۲	۵,۸٪	۹,۴٪
خوشه ۳	۳,۶٪	۷,۳٪
خوشه ۴	۸,۲٪	۱۰,۲٪
خوشه ۵	۴,۸٪	۵,۳٪
خوشه ۶	۵,۲٪	۵,۷٪
خوشه ۷	۲,۸٪	۳,۸٪

ماخذ: یافته‌های تحقیق

مطابق با نتایج بدست آمده حاصل از اجرای مدل پیشنهادی بر روی داده‌های سال ۱۳۹۵ و سال ۱۳۹۶، مشاهده می‌شود استفاده از الگوریتم ماشین بردار پشتیبان بر روی خوشه‌های رقابتی این دو سال، از دقت بالاتری نسبت به استفاده از الگوریتم ماشین بردار پشتیبان بدون در نظر گرفتن خوشه‌های رقابتی برخوردار می‌باشد.

همچنین مطابق با نتایج حاصل، مدل ارائه‌شده قابلیت پیش‌بینی قیمت تسویه بازار در سال ۹۵ را با متوسط دقت ۹۶ درصد و در سال ۹۶ را با متوسط دقت ۹۴ درصد دارد.

۵. نتیجه‌گیری

در این مطالعه، به بررسی روند قیمت تسویه در بازار روز بعد انرژی در کشور ایران پرداخته شده است، به گونه‌ای که در ابتدا فضای رقابتی در طول سال شناسایی شده و با استفاده از الگوریتم K-means، خوشه‌های رقابتی در طول سال تعیین گردید و به دنبال آن، با بکارگیری دوباره الگوریتم K-means برای هر خوشه، ساعات مربوط به روزهای هر خوشه نیز مجدداً خوشه‌بندی گردید که در نهایت، ۷ الگوی رقابتی برای بازار ایران شناسایی شده است.

با استفاده از الگوریتم ماشین‌بردار پشتیبان جهت پیش‌بینی قیمت تسویه بازار در هر یک از این خوشه‌های رقابتی، مطابق با نتایج بدست‌آمده از اجرای مدل برای داده‌های سال ۹۵، دقت مدل ۹۶ درصد و برای داده‌های سال ۹۶، دقت مدل ۹۴ درصد گزارش گردیده است و در تمامی حالات، دقت مدل پیشنهادی نسبت به حالت ماشین‌بردار پشتیبان ساده به صورت چشم‌گیری افزایش یافته است، به گونه‌ای که در بعضی از خوشه‌ها، دقت مدل پیشنهادی نسبت به مدل ماشین‌بردار پشتیبان ساده تا ۶/۵ درصد بهبود داشته است.

منابع

هیئت تنظیم بازار (۱۳۸۴)، آیین نامه معاملات شرکت‌های سهامی برق منطقه‌ای، مدیریت شبکه برق ایران، سازمان توسعه برق ایران، سازمان انرژی‌های نو ایران (سانا) و سازمان بهره‌وری انرژی ایران (سابا).

Amine Ladjici, Ahmed; Tiguercha, Ahmed and Mohamed Boudour (2012), "Equilibrium Calculation in Electricity Market Modeled as a Two-stage Stochastic Game Using Competitive Coevolutionary Algorithms", *IFAC Proceedings Vol. 45(21)*, pp. 524-529.

Amjady, N. (2006), "Day-ahead Price Forecasting of Electricity Markets by a New Fuzzy Neural Network", *IEEE Transactions on Power Systems*, 21(2), pp. 887-896.

Amjady, N; Daraeepour, A. and F. Keynia (2010), "Day-ahead Electricity Price Forecasting by Modified Relief Algorithm and Hybrid Neural Network", *IET Generation, Transmission & Distribution*, 4(3), pp. 432-444.

Bento, P. M. R; Pombo, J. A. N; Calado, M. R. A. and S. J. P. S. Mariano (2018), "A Bat Optimized Neural Network and Wavelet Transform Approach for Short-term Price Forecasting", *Applied Energy*, 210, pp. 88-97.

Catalão, J. P. S; Pousinho, H. M. I. and V. M. F. Mendes (2011), "Short-term Electricity Prices Forecasting in a Competitive Market by a Hybrid Intelligent Approach", *Energy Conversion and Management*, 52(2), pp.1061-1065.

Che, Jinxing, and Jianzhou Wang (2010), "Short-term Electricity Prices Forecasting Based on Support Vector Regression and Auto-regressive Integrated Moving Average Modeling", *Energy Conversion and Management*, 51(10), pp.1911-1917.

Ghadimi, N; Afkousi-Paqaleh, M and A. Nouri (2013), "PSO Based Fuzzy Stochastic Long-Term Model for Deployment of Distributed Energy Resources in Distribution Systems with Several Objectives", *IEEE Systems Journal*, 7(4), pp.786-796.

Gholipour Khajeh, Morteza; Maleki, Akbar; Rosen, Marc A. and Mohammad H. Ahmadi (2018), "Electricity Price Forecasting Using Neural Networks with an Improved Iterative Training Algorithm", *International Journal of Ambient Energy*, 39(2), pp. 147-158.

Gonzalez, A. M; Roque, A. M. S and J. Garcia-Gonzalez (2005), "Modeling and Forecasting Electricity Prices with Input/output Hidden Markov Models", *IEEE Transactions on Power Systems*, 20(1), pp. 13-24.

Grilli, Luca (2010), "Deregulated Electricity Market and Auctions: The Italian Case", *Scientific Research an Academic Publisher*, 2(3), pp. 238-242.

- Khashei, Mehdi; Mokhatab rafiei, Farimah and Mehdi Bijari** (2013), "Hybrid Fuzzy Auto-Regressive Integrated Moving Average (FARIMAH) Model for Forecasting the Foreign Exchange Markets", *International Journal of Computational Intelligence Systems*, 6(5), pp. 954-968.
- Khosravi, Abbas; Nahavandi, Saeid and Doug Creighton** (2013), "A Neural Network-GARCH-based Method for Construction of Prediction Intervals", *Electric Power Systems Research*, 96, pp. 185-193.
- Lago, Jesus; De Ridder, Fjo; Vrancx, Peter and Bart De Schutter** (2018), "Forecasting Day-ahead Electricity Prices in Europe: The Importance of Considering Market Integration", *Applied Energy*, 211, pp. 890-903.
- Lahmiri, Salim** (2014), "Wavelet Low- and High-frequency Components as Features for Predicting Stock Prices with Backpropagation Neural Networks", *Journal of King Saud University - Computer and Information Sciences*, 26(2), pp. 218-227.
- Lin, Whei-Min; Gow, Hong-Jey and Ming-Tang Tsai** (2010), "Electricity Price Forecasting Using Enhanced Probability Neural Network", *Energy Conversion and Management*, 51(12), pp. 2707-2714.
- Lo Prete, Chiara and Benjamin F. Hobbs** (2016), "A Cooperative Game Theoretic Analysis of Incentives for Microgrids in Regulated Electricity Markets", *Applied Energy*, 169, pp. 524-541.
- Lora, A. T; Santos, J. M. R; Exposito, A. G; Ramos, J. L. M and J. C. R. Santos** (2007), "Electricity Market Price Forecasting Based on Weighted Nearest Neighbors Techniques", *IEEE Transactions on Power Systems*, 22(3), pp. 1294-1301.
- Mok, Jie-Men** (2008), Process Scoring for Micro Credit Loans Thesis VU University Faculty of Exact Sciences Department of Business Mathematics and Informatics De Boelelaan 1081a 1081 HV Amsterdam The Netherlands.
- Niu, Dongxiao; Liu, Da and Desheng Dash Wu** (2010), "A Soft Computing System for Day-ahead Electricity Price Forecasting", *Applied Soft Computing*, 10(3), pp. 868-875.
- Nogales, F. J; and A. J. Conejo** (2006), "Electricity Price Forecasting Through Transfer Function Models", *Journal of the Operational Research Society*, 57(4), pp. 350-356.
- Nogales, F. J; Contreras, J; Conejo, A. J. and R. Espinola** (2002), "Forecasting Next-day Electricity Prices by Time Series Models", *IEEE Transactions on Power Systems*, 17(2), pp. 342-348.

Panapakidis, Ioannis P. and Athanasios S. Dagoumas (2016), "Day-ahead Electricity Price Forecasting via the Application of Artificial Neural Network Based Models", *Applied Energy*, 172, pp. 132-151.

Qi, Yongzhi; Liu, Yutian and Qiuwei Wu (2017), "Non-cooperative Regulation Coordination Based on Game Theory for Wind Farm Clusters during Ramping Events", *Energy*, 132, pp. 136-146.

Saini, D; Saxena, A. and R. C. Bansal (2016), Electricity Price Forecasting by Linear Regression and SVM, Paper presented at the 2016 International Conference on Recent Advances and Innovations in Engineering (ICRAIE).

Sandhu, Harmanjot Singh; Fang, Liping and Ling Guan (2016), "Forecasting Day-ahead Price Spikes for the Ontario Electricity Market", *Electric Power Systems Research*, 141, pp. 450-459.

Sansom, Damien C; Downs, Tom and Tapan K. Saha (2003), "Evaluation of Support Vector Machine Based Forecasting Tool in Electricity Price Forecasting for Australian National Electricity Market Participants", *Journal of Electrical & Electronics Engineering*, Australia, 22(3), p. 227.

Sulaiman, Mohd Herwan, Mustafa, Mohd Wazir, Shareef, Hussain, and Abd. Khalid, **Saiful Nizam**. (2012), "An application of Artificial Bee Colony Algorithm with Least Squares Support Vector Machine for Real and Reactive Power Tracing in Deregulated Power System", *International Journal of Electrical Power & Energy Systems*, 37(1), pp. 67-77.

Weron, Rafal (2014), "Electricity Price Forecasting: A Review of the State-of-the-art with a Look into the Future", *International Journal of Forecasting*, 30(4), pp. 1030-1081.

Xiao, Yi, Xiao, Jin, Lu, Fengbin, and Wang, Shouyang (2013), "Ensemble ANNs-PSO-GA Approach for Day-ahead Stock E-exchange Prices Forecasting", *International Journal of Computational Intelligence Systems*, 6(1), pp.96-114.

Yan, Xing, and Nurul A. Chowdhury (2014a), "Mid-term Electricity Market Clearing Price Forecasting Utilizing Hybrid Support Vector Machine and Auto-regressive Moving Average with External Input", *International Journal of Electrical Power & Energy Systems*, 63, pp. 64 -70.

Yan, Xing, and Chowdhury, Nurul A. (2014b), "Mid-term Electricity Market Clearing Price Forecasting: A Multiple SVM Approach", *International Journal of Electrical Power & Energy Systems*, 58, pp.206-214.

Yang, Zhang, Ce, Li, and Li. Lian (2017), "Electricity Price Forecasting by a Hybrid Model, Combining Wavelet Transform, ARMA and Kernel-based Extreme Learning Machine Methods", *Applied Energy*, 190, pp. 291-305.

Yousefi, G. Reza, Kaviri, Sajjad Makhdoomi, Latify, Mohammad Amin and Iman Rahmati (2017), "Electricity Industry Restructuring in Iran", *Energy Policy*, 108, pp. 212-226.

Zhang, Jinliang, Tan, Zhongfu, and Yang, Shuxia (2012), "Day-ahead Electricity Price Forecasting by a New Hybrid Method", *Computers & Industrial Engineering*, 63(3), pp. 695-701.

Zhao, J. H; Dong, Z. Y; Li, X. and K. P. Wong (2007), "A Framework for Electricity Price Spike Analysis with Advanced Data Mining Methods", *IEEE Transactions on Power Systems*, 22(1), pp. 376-385.