

پیش‌بینی کوتاه مدت قیمت تراکم گرهی در یک سیستم قدرت بزرگ تجدید ساختار یافته با استفاده از شبکه‌های عصبی مصنوعی با بهینه‌سازی آموزش ژنتیکی

رحمت‌الله هوشمند^۱ مجید معظمی^۲

۱- استاد- دانشکده مهندسی - گروه مهندسی برق - دانشگاه اصفهان - اصفهان- ایران

Hooshmand_r@eng.ui.ac.ir

۲- دانش‌آموخته- دکتری- دانشکده مهندسی - گروه مهندسی برق - دانشگاه اصفهان - اصفهان- ایران

m_moazzami@eng.ui.ac.ir

چکیده: در یک بازار برق روزانه، پیش‌بینی قیمت و بار مهمترین سیگنال برای شرکت کنندگان در بازار می‌باشد. در این مقاله از شبکه‌های عصبی پیشرو با بهینه‌سازی آموزش ژنتیکی برای پیش‌بینی قیمت کوتاه مدت تراکم گرهی برق در نواحی مختلف یک بازار برق در مقیاس وسیع استفاده شده است. اطلاعات لازم برای پایگاه داده شبکه عصبی از حل معادلات پخش بار بهینه سیستم قدرت با در نظر گرفتن کلیه عوامل موثر، برای تغییرات بار سیستم در هر ساعت از روز در مدت یک ماه حل شده است. ساختار شبکه عصبی دارای دو سیگنال ورودی توان اکتیو و راکتیو هر شین در هر ساعت از مدل برنامه‌ریزی می‌باشد. این دو سیگنال همواره در سیستم قدرت قابل دسترس می‌باشند. در این مطالعه از سیستم ۱۱۸ باسه IEEE برای بررسی صحت روش پیشنهادی استفاده شده است. این شبکه به ۳ ناحیه تقسیم شده و برای هر ناحیه از یک شبکه عصبی با آموزش بهینه ژنتیکی استفاده شده است. نتایج حاصله بیانگر توانایی این روش برای پیش‌بینی قیمت در یک بازار برق بزرگ با خطای نسبتاً کم و قابل قبول خصوصاً در نقاط جهش قیمت دارد.

کلمات کلیدی: پیش‌بینی قیمت - قیمت تراکم گرهی - شبکه‌های عصبی مصنوعی - الگوریتم ژنتیک.

تاریخ ارسال مقاله : ۱۳۸۹/۰۵/۱۱

تاریخ پذیرش مقاله : ۱۳۹۲/۰۸/۲۰

نام نویسنده‌ی مسئول : دکتر رحمت‌الله هوشمند

نشانی نویسنده‌ی مسئول: ایران - اصفهان - خیابان هزار جریب - دانشگاه اصفهان - دانشکده‌ی فنی و مهندسی - گروه مهندسی برق.

فهرست علائم

- I : مجموعه اندیس‌های واحدهای تولید.
- J : مجموعه اندیس‌های بارها.
- J_i : تعداد شین‌های دارای بار در هر ناحیه.
- B : مجموعه اندیس‌های باس‌های سیستم.
- N : مجموعه اندیس‌های خطوط انتقال.
- f_i : هزینه تولید توان اکتیو واحد i ام بر حسب $\$/MWh$.
- P_k : توان اکتیو تزریقی شبکه در گره $k \in B$ بر حسب MW.
- Q_k : توان راکتیو تزریقی شبکه در گره $k \in B$ بر حسب MVAR.
- P_{Gi} : تولید توان اکتیو اجباری واحد i ام.
- $P_{L\circ j}$: بار اکتیو غیر قابل قطع j ام.
- $Q_{L\circ j}$: تولید توان راکتیو اجباری واحد j ام.
- P_{gi} : توان اکتیو واحد i ام بر حسب MW.
- P_{Dj} : توان اکتیو بار j ام بر حسب MW.
- Q_{Dj} : توان راکتیو بار j ام بر حسب MW.
- Q_{gi} : توان راکتیو خروجی واحد i ام بر حسب MVAR.
- $R_{rAGC}(g_i)$: نرخ افزایش تولید توان اکتیو ژنراتور i ام برای تعقیب بار بر حسب MW/min.
- $R_rQ(g_i)$: نرخ افزایش تولید توان راکتیو ژنراتور i ام بر حسب MVAR/min.
- $P_{g\min i}$: حداقل توان اکتیو واحد i ام بر حسب MW.
- $P_{g\max i}$: حداکثر توان اکتیو واحد i ام بر حسب MW.
- $Q_{g\min i}$: حداقل توان راکتیو واحد i ام بر حسب MVAR.
- $Q_{g\max i}$: حداکثر توان راکتیو واحد i ام بر حسب MVAR.
- $P_{D\min j}$: حداقل توان اکتیو بار j ام بر حسب MW.
- $P_{D\max j}$: حداکثر توان اکتیو بار j ام بر حسب MW.
- $V_{\min k}$: حداقل ولتاژ شین k ام بر حسب پریونیت.
- $V_{\max k}$: حداکثر ولتاژ شین k ام بر حسب پریونیت.
- θ_k : زاویه ولتاژ شین k ام بر حسب پریونیت.
- $\phi_k j$: زاویه ادمیتانس خط بین شین‌های k و j .
- I_{mk} : جریان خط بین شین‌های m و k بر حسب پریونیت.
- P_{mk} : توان اکتیو خط جاری شده بین شین‌های m و k بر حسب پریونیت.
- $I_{mk\max}$: ماکزیمم جریان خط بین شین‌های m و k بر حسب پریونیت.
- $P_{mk\max}$: ماکزیمم توان خط بین شین‌های m و k بر حسب پریونیت.
- R_{gi} : توان رزرو اکتیو واحد i ام بر حسب MW.
- $R_{g\min i}$: حداقل توان اکتیو رزرو واحد i ام بر حسب MW.
- $R_{g\max i}$: حداکثر توان اکتیو رزرو واحد i ام بر حسب MW.
- P_{Aj} : قیمت واقعی شین j ام بر حسب $\$/MWh$.

۱- مقدمه

در بسیاری از کشورهای دنیا، سیستم‌های قدرت با انجام تجدید ساختار از یک سیستم متمرکز و عمودی به یک بازار برق باز با رقابت کامل تبدیل شده است. با آغاز تجدید ساختار در صنعت برق، قیمت برق، مورد توجه تمام فعالیت‌های موجود در بازار برق قرار گرفته است. قابل ذخیره نبودن انرژی الکتریکی، تعادل بین تولید و مصرف در هر لحظه، کنترل میزان انتقال توان به دلیل تراکم انتقال و ناآگاهی مصرف‌کنندگان و بی‌طرفی آنها نسبت به قیمت در کوتاه مدت، منجر به بی‌ثباتی قیمت و ایجاد پیک‌های ناخواسته در قیمت برق می‌شود [۱]. در یک بازار برق، پیش‌بینی قیمت و بار مهمترین سیگنال برای شرکت‌کنندگان در بازار می‌باشد. رشد اقتصادی، شرایط آب و هوایی، قیمت سوخت، اطلاعات قبلی بار و سابقه تاریخی قیمت برق در سیستم قدرت و کاهش تولید، از پارامترهای اثرگذار بر قیمت برق می‌باشند. همچنین قیمت برق با توجه به ساعت روز، روز هفته، تغییرات فصلها و تعطیلات تغییر می‌کند. بنابراین یک سیستم پیش‌بینی قیمت خوب باید بتواند با توجه به کلیه عدم قطعیت‌های موجود در سیستم، قیمت برق را با خطای قابل قبولی پیش‌بینی کند. در عین حال، در پیش‌بینی کوتاه مدت، مهمترین متغیر محرک قیمت، مقدار بار می‌باشد.

مدلهای پیش‌بینی قیمت عموماً به دو دسته مدل‌های سنتی و روش‌های مدرن تقسیم می‌شوند. مدل‌های سنتی پیش‌بینی قیمت، شامل مدل‌های سری زمانی و آنالیزهای رگرسیونی می‌باشند [۲]. در سالهای اخیر استفاده از روش‌های هوش مصنوعی برای پیش‌بینی قیمت بسیار متداول شده است. از میان این روش‌ها، شبکه‌های عصبی یک ابزار ساده و قدرتمند برای پیش‌بینی قیمت می‌باشد. شبکه‌های عصبی قادرند ارتباط بین ورودی و خروجی هر مسئله پیچیده را با استفاده از داده‌ها و سوابق تاریخی آن تعیین کنند. سریهای زمانی ارتباط میان قیمت برق و پارامترهای غیرخطی مصرف توان، شرایط آب و هوایی و مقدار تولید را بیان می‌کنند. از سریهای زمانی متداول می‌توان به روش ARIMA [۳]، آریمای فصلی SARIMA [۴] و GARCH [۵] اشاره کرد. در مرجع [۴] مکانیزم پیش‌بینی قیمت با استفاده از یک مدل ترکیبی از مدل SARIMA و یک مدل مارکو گسسته با پله‌های زمانی ناهمگن انجام شده است. در بازارهای برق کالیفرنیا و اسپانیا، از میان مدل‌های آماری، مدل‌های رگرسیون دینامیکی و تابع تبدیل، نتایج بهتری نسبت به مدل آریما ایجاد کرده‌اند [۶]. با پیشرفت روش‌های پیش‌بینی قیمت با استفاده از سریهای زمانی، در این بازارها از روش GARCH استفاده شده است [۶]. در مرجع [۷] از روش نزدیکترین همسایگان وزنی k ام با رگرسیون دینامیکی برای پیش‌بینی قیمت استفاده شده است. در مرجع [۸] از یک مدل تئوری بازی تصادفی و یک چارچوب حل آموزش توانمند برای پیش‌بینی قیمت در بازار برق

روز پیش استفاده شده است. از آنجایی که روشی برای حل دقیق تئوری بازی تصادفی وجود ندارد در این مرجع برای حل تقریبی مدل تئوری بازی تصادفی، یک ساختار آموزش مستحکم که ابزاری محاسباتی است استفاده شده است. این راه حل، یک استراتژی مناقصه موثر برای بیان دقیق مقدار قیمت در بازار روز پیش می باشد.

در کشورهای مختلف از شبکه های عصبی مصنوعی برای پیش بینی قیمت در سیستم های عملی استفاده شده است. در مراجع [۹-۱۱] از شبکه عصبی برای پیش بینی قیمت تسویه بازار MCP^۴ استفاده شده است و عدم قطعیت های موثر بر قیمت برق مورد بررسی قرار گرفته است. پیش بینی قیمت بر اساس شبکه های عصبی مصنوعی با موفقیت بر روی بازار برق کالیفرنیا [۶]، بازار عمده فروشی UK [۱۲]، PJM [۱۳] و بازار برق استرالیا [۱۴]، پیاده سازی شده است. در مرجع [۱۵] نشان داده شده است که برای داده های ورودی یکسان، استفاده از شبکه های عصبی پیشرو، دقیقتر و کارآمدتر از روشهایی مانند GARCH، ARMA، و حتی شبکه های هوشمند ANFIS^۵ و شبکه های عصبی بازگشتی می باشد. در مرجع [۱۶] از دو شبکه عصبی برای پیش بینی ساعتی قیمت متوسط موزون (WAP)^۶ و حداقل قابل قبول قیمت (MAP)^۷ در بازار برق ایران استفاده شده است. در این مرجع، قیمت متوسط موزون به صورت متوسط قیمت های قابل قبول وزن داده شده با استفاده از مقدار انرژی لازم در بازار برق تعریف شده است. همچنین استفاده از روشهای فازی و ترکیب آنها با شبکه های عصبی [۱]، روش ANFIS [۱۷]، روش SVM [۱۸]^۸، ترکیب شبکه های عصبی و فیلتر کالمن توسعه یافته [۱۳]، استفاده از ANN و Committee Machine [۹] نیز به عنوان ابزاری برای پیش بینی قیمت ارائه شده است. در مرجع [۱۴] از روش ARIMA و ANN به صورت ترکیبی برای پیش بینی قیمت در بازار برق استرالیا استفاده شده است. نتایج حاصله در این مرجع نشان می دهد که استفاده از این مدل ترکیبی نسبت به روش ARIMA و ANN به تنهایی، صحت بالاتری در پیش بینی قیمت برق داشته است.

در این مقاله از شبکه های عصبی پیشرو با بهینه سازی آموزش ژنتیکی برای پیش بینی قیمت تراکم گرهی برق (NCP)^۹ در نواحی مختلف یک بازار برق استفاده شده است. اطلاعات لازم برای پایگاه داده شبکه عصبی از حل معادلات پخش بار بهینه سیستم قدرت برای تغییرات بار سیستم در هر ساعت از روزهای یک ماه حل شده است. مدل برنامه ریزی استفاده شده، یک مدل غیرخطی در مقیاس وسیع هموار است. اطلاعات حاصله از روش پیش بینی قیمت پیشنهادی در نواحی مختلف و شدت تراکم هر ناحیه، جهت ایجاد هشدار برای ISO جهت تعادل سیستم و اعمال افزایش قیمت در آن ناحیه استفاده می شود. در این ساختار، شبکه عصبی دارای دو سیگنال ورودی توان اکتیو و راکتیو هر شین در هر ساعت از مدل برنامه ریزی می باشد. در این مطالعه از سیستم ۱۱۸ باسه IEEE برای بررسی نحوه عملکرد روش پیشنهادی استفاده شده است. این شبکه به ۳ ناحیه تقسیم شده

و برای هر ناحیه از یک شبکه عصبی با آموزش بهینه ژنتیکی استفاده شده است. نتایج حاصله بیانگر توانایی این روش برای پیش بینی قیمت با خطای نسبتاً کم و قابل قبول خصوصاً در نقاط پیک و جهش قیمت دارد.

۲- فرمول بندی مسئله پخش بار بهینه

منحنی قیمت بر خلاف منحنی بار، یک منحنی غیرمتجانس است و در تغییرات آن، ویژگی دوره ای کمی دیده می شود. اگرچه قیمت برق دارای بی ثباتی زیادی است، اما پدیده ای اتفاقی نیست. بنابراین می توان الگوها و قواعد مشخصی را غالب بر بی ثباتی بازار شناسایی کرد. استفاده از قیمت های پیشین، الگوهای مناسبی برای پیش بینی جهش های قیمت و احتمال وقوع آنها ارائه می دهد. دلیل اصلی بی ثباتی قیمت برق در اینست که عرضه و تقاضا باید در هر لحظه با هم برابر باشند. از دیگر دلایل بی ثباتی قیمت می توان به مواردی مانند بی ثباتی قیمت سوخت، فاکتور زمان، آب و هوا، انواع کلاس مشتریان، عدم قطعیت بار، تغییرات در تولید واحدهای برقی، عدم قطعیت تولید، تراکم انتقال، رفتار شرکت کنندگان در بازار بر اساس قیمت قابل پیش بینی، دست کاری بازار توسط عوامل موثر بر بازار و حوادث ویژه که منجر به افزایش شدید مصرف می شوند [۲۰-۱۹] اشاره نمود. در انجام شبیه سازی، با به کارگیری ملاحظات و قیود بهره برداری سیستم، به انجام یک پخش بار بهینه می پردازیم. با استفاده از داده های ورودی زیاد و وسیع، شبیه سازی می تواند بینش مطلوبی از منحنی قیمت ایجاد کند. شبیه سازی باید شامل مدل مشروح سیستم قدرت و روندی برای قیمت گذاری باشد. حال بر اساس مدل و روند یاد شده و مدل سازی ریاضی، پیش بینی قیمت صورت می گیرد. در شبیه سازی قیمت برق اطلاعاتی مانند مدل سیستم انتقال، برنامه ریزی مشارکت واحدها، توزیع انتقال مقید بار، توزیع انتقال ایمن بار و توانایی شبیه سازی سیستم با ابعاد بزرگ دارای اهمیت می باشد. مسئله بهینه سازی به صورت زیر بیان می شود.

$$\begin{aligned} \min \sum_i (f_i(P_{gi})) \\ s.t. \\ P_k &= \sum_{j \in B} |V_k| |V_j| |Y_{kj}| \cos(\phi_{kj} - \theta_k + \theta_j) = \sum_{i \in I_k} (P_{gi} + P_{gi}) - \sum_{j \in J_k} (P_{L,j} + P_{Dj}) \\ Q_k &= - \sum_{j \in B} |V_k| |V_j| |Y_{kj}| \sin(\phi_{kj} - \theta_k + \theta_j) = \sum_{i \in I_k} (Q_{gi}) - \sum_{j \in J_k} (Q_{L,j} + Q_{Dj}) \\ R_{AGC}(g_i) &\leq K, \forall i \in I \\ R_i Q(g_i) &\leq T, \forall i \in I \\ P_{g \min i} &\leq P_{gi} \leq P_{g \max i}, \forall i \in I \\ Q_{g \min i} &\leq Q_{gi} \leq Q_{g \max i}, \forall i \in I \\ P_{D \min j} &\leq P_{Dj} \leq P_{D \max j}, \forall j \in J \\ V_{\min k} &\leq V_k \leq V_{\max k}, \forall k \in B \\ |P_{mk}(\theta_k, V)| &\leq P_{mk \max}, \forall (mk) \in N \\ |P_{km}(\theta_k, V)| &\leq P_{km \max}, \forall (km) \in N \\ I_{mk}(\theta_k, V) &\leq I_{mk \max}, \forall (mk) \in N \\ I_{km}(\theta_k, V) &\leq I_{km \max}, \forall (km) \in N \\ R_{g \min i} &\leq R_{gi} \leq R_{g \max i}, \forall i \in I \end{aligned} \quad (1)$$

که f_i هزینه تولید توان اکتیو واحد i ام بوده و با استفاده از مدل درجه دوم مدل‌سازی شده‌اند. این مدل به صورت زیر می‌باشد:

$$f_i = C_0 + C_1 P + C_2 P^2 \quad (2)$$

همان گونه که قبلاً اشاره شد، این مسئله یک مسئله بهینه‌سازی غیرخطی در مقیاس وسیع^{۱۱} است. با حل مسئله و استفاده از قضیه KKT^{۱۱} ضرائب لاگرانژ بدست می‌آیند. ضرائب لاگرانژ بدست آمده با توجه به تابع لاگرانژ متناظر، هزینه تولید نهایی برق را با توجه به مصرف شبکه و در نظر گرفتن تلفات انتقال هر شین تعیین می‌کند. این روش حل، قیمت سایه‌ای^{۱۲} برق را با توجه به ارضای قیود شبکه و حفظ امنیت سیستم قدرت منعکس می‌کند که NCP^{۱۳} نامیده می‌شود. در فرمول‌بندی استفاده شده، جریان خطوط انتقال و ظرفیت توان اکتیو خطوط انتقال به عنوان پارامترهای امنیتی سیستم قدرت در نظر گرفته شده‌اند. در خلال تخمین مقادیر NCP در بازار برق تجدید ساختار یافته، مدیریت تراکم سیستم قدرت قابل دسترسی است. مقادیر NCP نه تنها نشان دهنده وجود تراکم در سیستم قدرت می‌باشند، بلکه شدت تراکم در شبکه را نیز به تصویر می‌کشند.

۳- روش پیشنهادی پیش‌بینی قیمت‌های تراکم گره‌ای

قیمت حاکم بر نقاط مختلف بازار وابسته به مشخصات فیزیکی سیستم قدرت و شرایط بهره‌برداری آن می‌باشد. حجم بالای اطلاعات و جهش‌های قیمت نیازمند استفاده از ابزاری توانا در جهت شناسایی قوانین حاکم بر آن می‌باشد. شبکه‌های عصبی به دلیل ویژگی منحصر به فردشان در شناسایی روابط و الگوهای حاکم بر اطلاعات یکی از ابزارهای کارآمد در پیش‌بینی قیمت می‌باشند که در این مطالعه نیز از آن استفاده شده است. انتخاب مناسب ورودیهای موثر بر قیمت تاثیر چشمگیری بر دقت آموزش و پاسخ شبکه عصبی خواهد داشت. در ادامه روند محاسبه اطلاعات پایگاه داده، انتخاب ورودیها و الگوریتم مورد استفاده بیان می‌شود.

۳-۱- دلایل انتخاب شبکه‌های عصبی برای پیش‌بینی قیمت

یکی از روشهای هوشمندی که امروزه حجم وسیعی از مطالعات پیش‌بینی قیمت و بار را به خود اختصاص داده است، شبکه‌های عصبی مصنوعی می‌باشد. روش شبکه‌های عصبی دارای مزایای زیادی نسبت به روشهای پیش‌بینی دیگر می‌باشد. مهمترین مزیت شبکه‌های عصبی، توانایی آموزش و یادگیری و کشف ارتباطات ورودی و خروجی از روی اطلاعات قبلی بار و قیمت، بدون نیاز به یک مدل مناسب می‌باشد. از محاسن شبکه‌های عصبی می‌توان به پیاده‌سازی آسان، عملکرد مناسب، مدل مشخص، سرعت بسیار قابل توجه، عملکرد مطلوب در فصول مختلف سال، عملکرد مطلوب در بارهای کم و زیاد اشاره کرد.

سرعت بالای شبکه عصبی، امکان پیش‌بینی قیمت با تمام قیود در بازار لحظه‌ای را نیز فراهم می‌کند. اصولاً تاثیر ظرفیت خطوط، وقفه‌های خطوط و وقفه‌های واحدهای نیروگاهی بر قیمت، متجانس هستند. به عبارت دیگر، اگر داده‌های پیشین به مقدار کافی داشته باشیم، قادر خواهیم بود با به کارگیری شبکه عصبی ارتباطهای بین این عوامل و قیمت را پیدا کنیم. تاثیرات الگوهای بار و الگوهای پیشنهاد قیمت بر قیمت، غیرمتجانس هستند که باید به کمک پخش بار بهینه (OPF) آنها را کشف کنیم. در روش فرمول‌بندی مورد استفاده برای این مطالعه، برای محاسبه مقادیر NCP در قیمت لحظه‌ای بازار از الگوی بازار حوضچه‌ای^{۱۴} استفاده می‌شود. در این شرایط، مقادیر قیمت‌های تراکم گرهی با توجه به قیود قیمت توان می‌باشد. این مقدار توسط مصرف کنندگان پرداخت و توسط تولیدکنندگان دریافت می‌شود. فرمول‌بندی مسئله OPF مبتنی بر استفاده از یک شین مبنا می‌باشد.

۳-۲- انتخاب ورودیها

قیمت‌های تراکم گرهی نسبت به شرایط عملکرد سیستم بسیار متغیر هستند و اساساً وابستگی زیادی به سناریوی بارگذاری سیستم قدرت دارند. با در نظر گرفتن این نکته، برای تخمین NCP، توان اکتیو و راکتیو بارهای شینه‌ها به عنوان ورودی‌های شبکه عصبی در نظر گرفته شده‌اند.

۳-۳- الگوریتم پیش‌بینی قیمت‌های تراکم گرهی

به طور خلاصه الگوریتم تخمین NCP با استفاده از شبکه عصبی دارای مراحل زیر می‌باشد:

۱- ایجاد سناریوهای بارگذاری ساعتی برای سیستم تحت مطالعه. در این بخش سناریوهای بارگذاری سیستم قدرت در ساعات مختلف یک روز و روزهای مختلف یک ماه ایجاد می‌شود. سناریوهای مورد بررسی ساعتی در روز و روزانه در خلال ماه، برای بارگذاریهای مختلف با توجه به تغییرات منحنی بار انجام شده است. در بعضی مراجع، سناریوهای بارگذاری سیستم قدرت به صورت تصادفی ایجاد می‌شوند که ممکن است با مقادیر واقعی عملکرد سیستم تفاوت داشته باشد [۱۱]. توجه به این نکته حائز اهمیت است که مقادیر NCP عمدتاً وابسته به شرایط بارگذاری سیستم قدرت می‌باشد.

۲- اجرای برنامه پخش بار بهینه برای محاسبه NCP در همه شین‌ها برای هر سناریوی بارگذاری. در این راستا برای هر سناریو با انجام پخش بار بهینه مطابق فرمول‌بندی رابطه (۱) قیمت‌های تراکم گرهی برای کلیه شین‌ها با در نظر گرفتن کلیه قیود مربوط به پخش بار و تراکم خطوط محاسبه می‌شود.

۳- انتخاب توانهای اکتیو و راکتیو شینه‌ها به عنوان ورودی و قیمت تراکم گرهی به عنوان خروجی شبکه عصبی و ایجاد یک شبکه عصبی مجزا برای هر ناحیه تراکم.

$$v^{k+1}(i) = \sum_{j=1}^{sk} w^{k+1}(i, j) y^k(j) + b^{k+1}(i) \quad (3)$$

$$y^{k+1}(i) = \phi^{k+1}(v^{k+1}(i)) \quad (4)$$

که sk تعداد خروجی‌ها در لایه k ام، $w^{k+1}(i, j)$ ، $b^{k+1}(i)$ و ϕ^{k+1} به ترتیب ضرایب وزنی سیناپسها، تابع بایاس و تابع تحریک نرون i ام در لایه $(k+1)$ می‌باشد. برای یک شبکه عصبی k لایه، معادلات ماتریسی سیستم به فرم زیر می‌باشد:

$$\bar{y}^0 = \bar{p} \quad (5)$$

$$\bar{y}^{k+1}(i) = \bar{\phi}^{k+1}(w^{k+1} \bar{y}^k + \bar{b}^{k+1}) \quad (k = 0, 1, \dots, k-1) \quad (6)$$

که بردار سیگنال ورودی $\bar{p}$ با متغیرهای Z به صورت $[p(1), p(2), \dots, p(Z)]^T$ توصیف می‌شود. برای آموزش شبکه عصبی از زوج بردارهای ورودی - خروجی $\{(\bar{p}_1, \bar{q}_1), (\bar{p}_2, \bar{q}_2), \dots, (\bar{p}_R, \bar{q}_R)\}$ استفاده می‌شود. با نشان دادن مجموع مجذور خطای سیگنال خروجی با اندیس عملکردی^{۱۶}، خطای شبکه عصبی با استفاده از تابع خطای زیر بدست می‌آید:

$$E = \frac{1}{2} \sum_{r=1}^R (\bar{q}_r - \bar{y}_r^k)^T (\bar{q}_r - \bar{y}_r^k) = \frac{1}{2} \sum_{r=1}^R (\bar{e}_r)^T \bar{e}_r \quad (7)$$

که $\bar{e}_r = \bar{q}_r - \bar{y}_r^k$ خطای خروجی و $\bar{y}_r^k$ خروجی نهایی ورودی r ام می‌باشد.

حال تابع مجموع مجذور خطای $E(\bar{x})$ به عنوان تابع هدف به صورت زیر استفاده می‌شود:

$$E(\bar{x}) = \frac{\sum_{i=1}^N e_i^T(x)}{N} \quad (8)$$

برای حداقل نمودن این تابع هدف از روش نیوتن و بر اساس رابطه زیر استفاده می‌شود:

$$\Delta \bar{x} = - \left[\nabla^2 E(\bar{x}) \right]^{-1} \nabla E(\bar{x}) \quad (9)$$

که در این رابطه:

$$\nabla E(\bar{x}) = J^T(\bar{x}) \cdot \bar{e}(\bar{x}) \quad \text{و} \quad \nabla^2 E(\bar{x}) = J^T(\bar{x}) \cdot J(\bar{x}) + S(\bar{x})$$

است که $J(\bar{x})$ ماتریس ژاکوبین و $\bar{e}(\bar{x}) = \nabla^T \bar{e}_i(\bar{x})$ می‌باشد [۲۱].

در این روش، برای به روز کردن رابطه (۹) از رابطه (۱۰) استفاده می‌شود. در این حالت فرض می‌شود که $S(\bar{x}) = 0$ است. لذا،

$$\Delta(\bar{x}) = - \left[J^T(\bar{x}) \cdot J(\bar{x}) \right]^{-1} J^T(\bar{x}) \cdot \bar{e}(\bar{x}) \quad (10)$$

الگوریتم لونیبرگ - مارکوارت، روش نیوتن را با استفاده از رابطه زیر اصلاح می‌کند:


$$\Delta(\bar{x}) = - \left[J^T(\bar{x}) \cdot J(\bar{x}) + \mu \cdot I \right]^{-1} J^T(\bar{x}) \cdot \bar{e}(\bar{x}) \quad (11)$$

که پارامتر μ مطابق با تغییر اندیس عملکرد در هر تکرار فرآیند آموزش، به روز می‌شود. در این رابطه، I ماتریس شناسایی^{۱۷} می‌باشد.

۴- آموزش بهینه شبکه عصبی هر ناحیه با استفاده از آموزش ژنتیکی.

۵- تست شبکه عصبی برای الگوهای جدید بارگذاری مختلف منظور نشده در پایگاه داده آموزش شبکه عصبی و پیش‌بینی قیمت‌های تراکم گرهی.

با توجه به این مراحل فلوچارت روش مورد استفاده در این مطالعه در شکل (۱) نشان داده شده است.



شکل (۱): فلوچارت روش مورد استفاده برای تخمین قیمت تراکم گرهی

۴- ساختار شبکه عصبی مورد استفاده با آموزش ژنتیکی

ژنتیکی

الگوریتم آموزش لونیبرگ - مارکوارت نسبت به سایر روشهای آموزش شبکه عصبی دارای سرعت بالاتری می‌باشد. با توجه به وسعت داده‌ها در این مطالعه، از این الگوریتم برای آموزش شبکه‌های عصبی نواحی سه‌گانه سیستم قدرت تحت مطالعه استفاده شده است. جهت حصول خطای آموزش کمتر، از الگوریتم ژنتیک برای بهینه‌سازی انتخاب ورودیها، اندازه پله‌ها، مقادیر ممنوم و تعداد المانهای پردازش لازم در لایه مخفی استفاده شده است. برای بررسی نحوه عملکرد شبکه آموزش دیده، معیارهای MAE ، $RMSE$ ، MSE ، حداقل و حداکثر خطای مطلق در تست شبکه عصبی بیان شده‌اند.

۴-۱- الگوریتم شبکه عصبی لونیبرگ - مارکوارت با انتشار پسرو (LMBP)^{۱۵}

برای یک شبکه چند لایه، ورودی $v^{k+1}(i)$ و خروجی $y^{k+1}(i)$ ام از نرون i ام و در لایه $k+1$ ام به ترتیب توسط روابط (۳) و (۴) توصیف می‌شوند:

$$MSE = \frac{\sum_{j=1}^{J_i} (P_{Aj} - P_{Fj})^2}{J_i} \quad (12)$$


$$RMSE = \sqrt{\frac{\sum_{j=1}^{J_i} (P_{Aj} - P_{Fj})^2}{J_i}} \quad (13)$$

$$MAE = \frac{\sum_{j=1}^{J_i} (P_{Aj} - P_{Fj})}{J_i} \quad (14)$$

۵- نتایج شبیه سازی

۵-۱- سیستم قدرت تحت مطالعه

در این مقاله سیستم قدرت استاندارد ۱۱۸ باسه IEEE به عنوان سیستم تست انتخاب شده است. این سیستم دارای ۵۴ ژنراتور، ۱۸۶ خط انتقال، ۱۴ خازن و ۹ ترانس تپ چنجر دار می باشد. اطلاعات این سیستم در مرجع [۲۲] آمده است. نمایش تک خطی این سیستم و نواحی سه گانه آن در شکل (۲) نشان داده شده است. با توجه به تغییرات فصول، مقدار پیک بار این سیستم در ساعت ۲۱ رخ داده و مقدار آن به ۷۳۰۶ MW می رسد [۲۳].



شکل (۲): دیاگرام تک خطی سیستم قدرت ۱۱۸ باسه IEEE و نحوه ناحیه بندی آن

برای ایجاد پایگاه داده مورد استفاده برای آموزش شبکه عصبی، پخش بار بهینه برای سناریوهای بارگذاری ساعتی سیستم قدرت در طول دوره ۲۴ ساعته یک روز انجام شده است. این روال برای یک ماه بارگذاری روزانه سیستم با احتساب تغییرات منحنی بار انجام شده و اطلاعات لازم برای آموزش شبکه عصبی بدست آمده است. لازم به ذکر است که قیمت تراکم گرهی NCP برای کلیه شینه های بار محاسبه شده است. کلیه مطالعات و شبیه سازیها برای کل سیستم قدرت انجام شده است و تمام قیود تراکم خطوط انتقال بدون

برای الگوریتم LMBP، ابتدا زوج بردارهای ورودی- خروجی R به شبکه داده می شود. سپس خروجی ها و خطا با استفاده از معادلات (۵)، (۶) و (۸) محاسبه می گردند. در مرحله بعد، ماتریس ژاکوبین و تغییرات افزایشی $\Delta \bar{x}$ از رابطه (۱۱) بدست می آید. در نهایت، اندیس عملکرد از جایگزینی $\bar{x}$ با $\bar{x} + \Delta \bar{x}$ در رابطه $E(\bar{x})$ مجدداً محاسبه می شود. زمانی که اندیس عملکرد، کمتر از یک مقدار خطای مشخص شود، شبکه عصبی، همگرا می گردد.

۴-۲- نحوه آموزش ژنتیکی


در این مقاله، آموزش شبکه عصبی به صورت ژنتیکی انجام شده است. این ساختار جهت بهینه سازی ژنتیکی شبکه عصبی، انتخاب ورودیها، اندازه پله ها، مقادیر ممنوع و تعداد المانهای پردازش لازم در لایه مخفی استفاده شده است. هدف بهینه سازی، یافتن بهترین تنظیم پارامترها به گونه ای است که خطای آموزش به مینیمم مقدار خود برسد. اگر در روال آموزش از Cross Validation استفاده شود، هدف مینیمم کردن خطای آن بوده و در غیر اینصورت هدف مینیمم کردن خطای آموزش می باشد. بهترین وزن ها و تنظیم پارامترهای بدست آمده در خلال آموزش برای شبکه عصبی انتخاب می شوند. بدین منظور ابتدا جمعیت اولیه ای از شبکه های عصبی به طور تصادفی ایجاد می شود که هر کدام دارای تنظیم پارامترهای متفاوتی می باشند. سپس همه این شبکه های عصبی آموزش داده شده و جهت تشخیص و تعیین بهترین برازندگی جهت رسیدن به مینیمم خطای آموزش ارزیابی می شوند. در ادامه ویژگیهای بهترین شبکه ها با هم ترکیب شده و با اعمال عملگر جهش بر روی آنها جمعیت جدیدی از شبکه های عصبی ایجاد می شود. مجدداً شبکه های عصبی موجود در این جمعیت ارزیابی شده و بهترین شبکه ها انتخاب شده و نسل بعدی را ایجاد می کنند. این فرآیند تا زمانی که به حداکثر شماره جمعیت مورد استفاده و یا ماکزیمم زمان ارزیابی برسیم، تکرار می شود. در نهایت مشخصات بهترین شبکه عصبی مشخص و مورد استفاده قرار می گیرد. این امر خصوصاً در این مطالعه که پایگاه داده دارای مقدار زیادی داده است منجر به آموزشهای بسیار بهتری می شود.

۴-۳- معیارهای ارزیابی و تست شبکه عصبی


برای بررسی نحوه عملکرد شبکه عصبی در پیش بینی قیمت معیارهای استاندارد مقادیر مجذور میانگین خطا ($^1 MSE$)، ریشه مجذور میانگین خطا ($^9 RMSE$)، میانگین خطای مطلق ($^2 MAE$) و حداقل و حداکثر خطای مطلق که به صورت زیر بیان می شوند، برای موارد تست شده محاسبه می شوند [۱۵]. هرچه مقادیر MSE ، $RMSE$ و MAE کمتر باشند شبکه عصبی بهتر آموزش دیده است و رفتار بهتر و خطای کمتری در شرایط تست الگوهای جدید بارگذاری خواهد داشت.

جدول (۲): پارامترهای آموزش ژنتیکی شبکه‌های عصبی استفاده شده در هر ناحیه


پارامترهای آموزش ژنتیکی	ناحیه ۱	ناحیه ۲	ناحیه ۳
حداکثر تعداد تکرارها (Epoch)	۵۰۰۰	۵۰۰	۱۰۰۰
اندازه جمعیت اولیه شبکه‌های عصبی	۲۰	۲۰	۲۰
ماکزیمم تکرار جمعیت مورد استفاده	۲۵	۲۵	۲۵
اپراتور انتخاب	چرخ رولت	چرخ رولت	چرخ رولت
اپراتور Crossover	ابتکاری ^{۳۱}	ابتکاری	ابتکاری
احتمال Crossover	۰/۷	۰/۶	۰/۶
اپراتور جهش	یکنواخت ^{۳۲}	یکنواخت	یکنواخت
احتمال جهش	۰/۰۳	۰/۰۳	۰/۰۳



(۲ الف)



(۳ ب)



(۴ ج)

شکل (۳): اطلاعات پایگاه داده ناحیه (۱); (الف): تغییرات قیمت یک

مگاوات ساعت انرژی بر حسب (\$/MWh)

ب): تغییرات توان اکتیو و راکتیو بارها; (ج): تغییرات قیمت توان اکتیو

براساس تغییرات توان اکتیو باس‌ها بر حسب (\$/MWh)

در نظر گرفتن تقسیم بندی شکل (۲) انجام شده است. برای جلوگیری از حجم بالای پایگاه داده شبکه عصبی و افزایش زمان آموزش آن از سه ناحیه متداول و مرسوم در سیستم ۱۱۸ باس IEEE استفاده شده و برای هر ناحیه از یک شبکه عصبی استفاده شده است.

با توجه به تقسیم‌بندی این شبکه به ۳ ناحیه، در ناحیه اول ۲۲۶۱۱، در ناحیه دوم ۲۴۹۶۹ و در ناحیه سوم ۱۶۱۷۲ دسته اطلاعات برای پایگاه داده شبکه عصبی حاصل شده است. این مقادیر بدون احتساب اطلاعات روزهای ۱۰ام، ۱۹ام و ۲۵ام که برای تست شبکه عصبی انتخاب شدند، می‌باشد.

۲-۵- مشخصات شبکه عصبی با آموزش ژنتیکی


به منظور حصول آموزش مناسب برای شبکه عصبی، برای هر ناحیه یک شبکه عصبی در نظر گرفته شده است. برای رسیدن به رفتار مناسب شبکه عصبی در پیش‌بینی قیمت، شبکه‌های عصبی زیادی آموزش داده شده است. مشخصات و پارامترهای بهترین شبکه عصبی بدست آمده برای هر ۳ ناحیه سیستم قدرت در جدول (۱) آورده شده است. شرایط استفاده شده برای آموزش ژنتیکی شبکه عصبی در جدول (۲) نشان داده شده است.

جدول (۱): مشخصات و پارامترهای شبکه‌های عصبی استفاده شده


برای هر ناحیه

پارامترهای ANN	ناحیه ۱	ناحیه ۲	ناحیه ۳
تعداد نرونها ورودی	۲	۲	۲
تعداد نرونها خروجی	۱	۱	۱
تعداد لایه‌های پنهان	۲	۲	۱
تعداد نرونها لایه پنهان	(۴) - ۲, (۵) - ۱	(۶) - ۲, (۷) - ۱	۲۰
پیشرو توسعه یافته	پیشرو توسعه یافته	پیشرو توسعه یافته	پیشرو توسعه یافته
مدل شبکه عصبی مورد استفاده	LMBP	LMBP	LMBP
الگوریتم آموزش شبکه	تأزانت هیپربولیک	تأزانت هیپربولیک	تأزانت هیپربولیک
تابع تبدیل نرونها لایه میانی	تأزانت هیپربولیک	تأزانت هیپربولیک	تأزانت هیپربولیک
تابع تبدیل نرونها لایه خروجی	تأزانت هیپربولیک	تأزانت هیپربولیک	تأزانت هیپربولیک
حداکثر تعداد تکرارها (Epoch)	۵۰۰۰	۵۰۰	۱۰۰۰
آستانه خطا	۰/۰۰۱	۰/۰۰۱	۰/۰۰۱
روش به روز کردن خطا	batch	batch	Batch


تغییرات قیمت یک مگاوات ساعت انرژی بر حسب دلار بر مگاوات ساعت در شینه‌های ناحیه ۱ سیستم قدرت در پایگاه داده مورد استفاده در آموزش شبکه عصبی در شکل (۳ الف) نشان داده شده است. در شکل (۳ ب) نحوه تغییرات توان اکتیو و راکتیو بارهای ناحیه ۱ دیده می‌شود. در شکل (۳ ج) تغییرات قیمت توان اکتیو بارهای ناحیه ۱ بر اساس تغییرات مقدار توان اکتیو باس‌بارها بر حسب (\$/MWh) مشاهده می‌شود. نحوه تغییرات ذکر شده برای ناحیه ۱ به طور مشابه برای نواحی ۲ و ۳ به ترتیب در شکل‌های (۴) و (۵) نشان داده شده است.



(الف ۵)




(ب ۵)




(ج ۵)


شکل (۵): اطلاعات پایگاه داده ناحیه (۳); (الف): تغییرات قیمت یک مگاوات ساعت انرژی بر حسب (\$/MWH)
 (ب): تغییرات توان اکتیو و راکتیو بارها; (ج): تغییرات قیمت توان اکتیو بر اساس تغییرات توان اکتیو باس‌ها بر حسب (\$/MWH)



(الف ۴)



(ب ۴)




(ج ۴)

شکل (۴): اطلاعات پایگاه داده ناحیه (۲); (الف): تغییرات قیمت یک مگاوات ساعت انرژی بر حسب (\$/MWH)
 (ب): تغییرات توان اکتیو و راکتیو بارها; (ج): تغییرات قیمت توان اکتیو بر اساس تغییرات توان اکتیو باس‌ها بر حسب (\$/MWH)

خروجی شبکه عصبی بر اثر تغییرات یک ورودی به چه شکل تغییر می‌کند. بدین منظور ورودی اول حول مقدار متوسط انحراف معیار استاندارد تعیین شده در زمان شبیه‌سازی (در اینجا ۱) تغییر داده می‌شود، در حالیکه سایر ورودیها نسبت به مقدار میانگین ثابت هستند. در این شرایط خروجی شبکه عصبی برای این عدد مشخص شده در بالا و پایین مقدار میانگین محاسبه می‌شود. این پروسه برای هر ورودی تکرار می‌شود. همانگونه که در شکل (۷) مشاهده می‌شود با توجه به آموزش حاصل شده برای ناحیه ۱، حساسیت قیمت به مقادیر P و Q بیشتر از حساسیت مورد نظر در نواحی دیگر می‌باشد. تغییرات مقادیر قیمت بر حسب تغییرات توان اکتیو و راکتیو شینه‌ها در کلیه نواحی در


مقادیر حداقل و نهایی خطای آموزش شبکه عصبی در هر سه ناحیه و مشخصات ژنتیکی آن در جدول (۳) آورده شده است. بهترین مقدار برازندگی تابع معیار (MSE) و مقدار متوسط برازندگی تابع معیار (MSE) شبکه عصبی در خلال فرایند آموزش نواحی به ترتیب در شکلهای (۶ الف) و (۶ ب) مشاهده می‌شود. در شکل (۷) حساسیت شبکه عصبی نسبت به پارامترهای ورودی آن در شرایط تست در هر ۳ ناحیه نشان داده شده است و ماکزیمم حساسیت قیمت نسبت به تغییرات توان اکتیو و راکتیو در همه نواحی در جدول (۴) آورده شده است. پروسه تعیین حساسیت به اندازه‌گیری اهمیت نسبی بین ورودیهای شبکه عصبی می‌پردازد. این ساختار نشان می‌دهد که هر




شکل (۷): حساسیت شبکه عصبی نسبت به پارامترهای ورودی آن در شرایط تست در هر ۳ ناحیه

جدول (۴): ماکزیم حساسیت قیمت نسبت به تغییرات توان اکتیو و راکتیو در نواحی سه گانه

شماره ناحیه	پارامترهای ورودی	ماکزیم حساسیت قیمت
ناحیه ۱	P	۰/۴۳۹۸۹۵۶۹۳
	Q	۰/۲۲۹۵۴۲۷۸
ناحیه ۲	P	۰/۰۷۵۹۴۲۴۷۹
	Q	۰/۰۹۴۳۲۴۸۹۱
ناحیه ۳	P	۰/۰۴۹۰۳۰۱۱۸
	Q	۰/۰۵۹۷۲۲۰۹۵



شکل (۸): تغییرات مقادیر قیمت بر حسب تغییرات توان اکتیو (MW) شینه‌ها در نواحی سه گانه




شکل (۹): تغییرات مقادیر قیمت بر حسب تغییرات توان راکتیو (MVAR) شینه‌ها در نواحی سه گانه

است که احتمال جهش‌های قیمت در آن زیاد است. مقدار قیمت کلیه شینه‌های دارای بار در هر ۳ ناحیه سیستم قدرت تحت مطالعه در


شرایط تست به ترتیب در شکل‌های (۸) و (۹) نشان داده شده است. بر اساس این ۲ شکل، منطقه ۲ از تراکم بین منطقه‌ای بیش از مناطق دیگر برخوردار می‌باشد. همچنین رنج تغییرات توان اکتیو و راکتیو دیده شده در این دو شکل نشان می‌دهند که به دلیل افزایش تراکم در ناحیه ۲، مطابق با شکل (۴ الف) رنج تغییرات قیمت در این ناحیه بیشتر از سایر نواحی بوده است.

جدول (۳): حداقل و مقدار نهایی خطای آموزش شبکه عصبی با آموزش ژنتیکی در هر ۳ ناحیه

شماره ناحیه	خلاصه اطلاعات بهینه‌سازی	بهترین برازندگی	متوسط برازندگی
ناحیه ۱	تکرارها	۱۷	۲۳
	حداقل MSE	۰/۰۱۴۰۳۸۲۲۴	۰/۰۱۴۷۵۰۲۵۶
	MSE نهایی	۰/۰۱۴۰۳۸۲۲۴	۰/۰۱۹۵۵۷۵۴۳
ناحیه ۲	تکرارها	۱۹	۲۴
	حداقل MSE	۰/۰۱۲۸۴۰۱۶۹	۰/۰۱۳۶۳۷۶۶۲
	MSE نهایی	۰/۰۱۲۸۴۰۱۶۹	۰/۰۱۶۶۱۷۹۳۵
ناحیه ۳	تکرارها	۱۹	۲۴
	حداقل MSE	۰/۰۱۲۸۴۰۱۶۹	۰/۰۱۳۶۳۷۶۶۲
	MSE نهایی	۰/۰۱۲۸۴۰۱۶۹	۰/۰۱۶۶۱۷۹۳۵



(۶ الف)



(۶ ب)

شکل (۶): (۶ الف): بهترین مقدار برازندگی تابع معیار (MSE) شبکه عصبی در خلال فرآیند آموزش نواحی سه گانه
(۶ ب): مقدار متوسط برازندگی تابع معیار (MSE) شبکه عصبی در خلال فرآیند آموزش نواحی سه گانه

برای بررسی نحوه عملکرد روش پیشنهادی، ساعت ۱۹ به عنوان تست استفاده می‌شود. این ساعت یکی از ساعتهای نزدیک به پیک بار شبکه

روزهای ۱۰ ام، ۱۹ ام و ۲۵ ام که از ابتدا برای تست شبکه‌های عصبی نتایج برای روز ۱۹ ام در جدول (۵) آورده شده است.
۳ ناحیه در نظر گرفته شده بودند، پیش‌بینی شده‌اند. به عنوان نمونه،

جدول (۵): پیش‌بینی قیمت هر سه ناحیه سیستم قدرت برای ساعت ۱۹ در روز ۱۹

مقادیر توان اکتیو و راکتیو بر حسب MW و MVAR و کلیه مقادیر قیمت واقعی و پیش‌بینی شده بر حسب \$/MWh می‌باشد.

روز ۱۹ - ساعت ۱۹ - ناحیه ۱					روز ۱۹ - ساعت ۱۹ - ناحیه ۲					روز ۱۹ - ساعت ۱۹ - ناحیه ۳				
شماره شین	P (MW)	Q (MVAR)	قیمت واقعی	قیمت پیش‌بینی شده	شماره شین	P (MW)	Q (MVAR)	قیمت واقعی	قیمت پیش‌بینی شده	شماره شین	P (MW)	Q (MVAR)	قیمت واقعی	قیمت پیش‌بینی شده
۱	۷۶/۷۸	۵۷/۸۲	۲۴/۵۹۶	۲۴/۰۶	۳۳	۳۴/۶۲	۱۹/۲۷	۲۴/۱۴۸	۲۳/۶۰	۸۲	۸۱/۳۹	۵۷/۸۲	۲۱/۱۷۸	۲۰/۷۷
۲	۳۰/۱	۱۹/۲۷	۲۴/۱۳۴	۲۳/۸۵	۳۴	۸۸/۸۲	۵۵/۶۸	۲۳/۷۱۶	۲۳/۴۶	۸۳	۳۰/۱	۲۱/۴۲	۲۰/۸۸۸	۱۹/۸۲
۳	۵۸/۷۲	۲۱/۴۲	۲۴/۲۵۵	۲۳/۴۵	۳۵	۴۹/۶۹	۱۹/۲۷	۲۳/۶۸	۲۳/۸۱	۸۴	۱۶/۵۶	۱۴/۹۹	۲۰/۰۷۹	۱۹/۱۹
۴	۵۸/۷۲	۲۵/۷	۲۳/۳۴۸	۲۳/۸۱	۳۶	۴۶/۶۸	۳۶/۴	۲۳/۶۴۱	۲۱/۶۸	۸۵	۳۶/۱۲	۳۲/۱۲	۱۹/۴۲۹	۱۸/۱۴
۶	۷۸/۲۸	۴۷/۱۲	۲۳/۶۸۸	۲۳/۱۵	۳۹	۴۰/۶۵	۲۳/۵۶	۲۵/۰۷۵	۲۴/۲۱	۸۶	۳۱/۶۱	۲۱/۴۲	۱۵/۹۶۳	۱۶/۷۶
۷	۲۸/۶	۴/۲۹	۲۳/۷۰۱	۲۳/۵۹۸	۴۰	۹۹/۳۶	۴۹/۲۷	۲۵/۵۲۶	۲۳/۶۷	۸۸	۷۲/۲۶	۲۱/۴۲	۱۹/۶۹۷	۲۰/۰۶
۸	۴۲/۱۶	۰	۲۳/۲۲۷	۲۳/۹۴۷	۴۱	۵۵/۷۱	۲۱/۴۲	۲۵/۷۵۷	۲۵/۹۹	۹۰	۲۴۵/۳۹	۸۹/۹۶	۲۰/۶۱۷	۱۹/۲۸
۱۱	۱۰۵/۳۸	۴۹/۲۷	۲۳/۷۵۵	۲۳/۴۵	۴۲	۱۴۴/۵۳	۴۹/۲۷	۲۵/۲۸	۲۴/۱۸	۹۱	۱۵/۰۵	۰	۲۰/۱۲۳	۱۸/۶۰
۱۲	۷۰/۷۶	۲۱/۴۲	۲۳/۶۱۶	۲۳/۹۵	۴۳	۲۷/۰۹	۱۴/۹۹	۲۴/۳۰۶	۲۴/۸۴	۹۲	۹۷/۸۵	۲۱/۴۲	۱۹/۴۳۹	۲۰/۵۹
۱۳	۵۱/۱۹	۳۴/۲۶	۲۴/۲۳۷	۲۳/۸۲	۴۴	۲۴/۰۸	۱۷/۱۳	۲۴/۲۸۲	۲۴/۵۹	۹۳	۱۸/۰۶	۱۴/۹۹	۲۰/۰۴۱	۱۹/۰۹
۱۴	۲۱/۰۷	۲/۱۴	۲۳/۸۵۸	۲۳/۶۱	۴۵	۷۹/۷۹	۴۷/۱	۲۳/۹۷۴	۲۳/۸۴	۹۴	۴۵/۱۵	۳۴/۲۶	۲۰/۴۲۳	۱۹/۰۲
۱۵	۱۳۵/۴۹	۶۴/۲۵	۲۳/۹۷۶	۲۳/۹۹	۴۶	۴۲/۱۶	۲۱/۴۲	۲۳/۷۷۲	۲۱/۸۶	۹۵	۶۳/۲۲	۶۶/۳۹	۲۰/۹۹۱	۲۱/۴۷
۱۶	۳۷/۶۴	۲۱/۴۲	۲۳/۷۱۸	۲۴/۰۶	۴۷	۵۱/۱۹	۰	۲۳/۷۰۲	۲۱/۸۶	۹۶	۵۷/۳۱	۳۲/۱۲	۲۱/۲۴۴	۲۰/۷۱
۱۷	۱۶/۵۶	۶/۴۳	۲۳/۱۶	۲۳/۷۳	۴۸	۳۰/۱	۲۳/۵۶	۲۳/۶۶۳	۲۱/۵۹	۱۰۰	۵۵/۷۱	۳۸/۵۵	۱۹/۵۴۸	۲۰/۶۷
۱۸	۹۰/۳۲	۷۲/۸۳	۲۳/۵۲۱	۲۳/۹۳	۴۹	۱۳۰/۹۶	۶۴/۲۵	۲۳/۴۰۸	۲۳/۵۳	۱۰۱	۳۳/۱۱	۳۲/۱۲	۱۹/۷۱۴	۱۸/۱۲
۱۹	۶۷/۷۵	۵۲/۳۳	۲۳/۹۲۸	۲۳/۱۰	۵۰	۲۵/۵۹	۸/۵۷	۲۳/۷۳۴	۲۰/۳۹	۱۰۲	۷/۵۳	۶/۴۳	۱۹/۵۵۲	۱۷/۸۷
۲۰	۲۷/۰۹	۶/۴۳	۲۴/۰۳۵	۲۳/۴۲	۵۱	۲۵/۵۹	۱۷/۱۳	۲۳/۱۳۹	۲۳/۸۲	۱۰۳	۳۴/۶۲	۳۴/۲۶	۱۹/۸۰۹	۱۸/۳۱
۲۱	۲۱/۰۷	۱۷/۱۳	۲۳/۸۲۹	۲۳/۵۹	۵۲	۲۷/۰۹	۱۰/۷	۲۳/۳۱۴	۲۳/۴۹	۱۰۴	۵۷/۳۱	۵۳/۵۳	۱۹/۸۸۲	۲۰/۰۳
۲۲	۱۵/۰۵	۱۰/۷	۲۳/۳۵۳	۲۴/۱۹	۵۳	۳۴/۶۲	۲۳/۵۶	۲۳/۱۰۴	۲۱/۵۸	۱۰۵	۴۶/۶۸	۵۵/۶۸	۲۰/۰۶۲	۱۹/۸۹
۲۳	۱۰/۵۴	۶/۴۳	۲۳/۴۱۸	۲۱/۹۸	۵۴	۱۷۰/۱۱	۶۸/۵۴	۲۳/۵۵۳	۲۳/۹۱	۱۰۶	۶۴/۷۴	۳۴/۲۶	۲۰/۳۸۴	۲۲/۳۶
۲۴	۱۹/۵۷	۰	۲۳/۶۵۶	۲۳/۶۷	۵۵	۹۴/۸۴	۴۷/۱۲	۲۳/۵۷۴	۲۳/۳۷	۱۰۷	۷۵/۲۶	۲۵/۷	۲۰/۹۴۹	۲۲/۶۸
۲۷	۱۰۶/۸۸	۲۷/۸۵	۲۳/۳۲۶	۲۴/۱۵	۵۶	۱۲۶/۴۶	۳۸/۵۵	۲۳/۶۰۳	۲۳/۱۸	۱۰۸	۳/۰۱	۲/۴۵	۲۰/۰۴۱	۱۸/۴۹
۲۸	۲۵/۵۹	۱۴/۹۹	۲۳/۶۹۹	۲۳/۲۴	۵۷	۱۸/۰۶	۶/۴۳	۲۳/۸۱	۲۰/۰۳	۱۰۹	۱۲/۰۴	۶/۴۳	۲۰/۰۲	۱۹/۶۵
۲۹	۳۶/۱۲	۸/۵۷	۲۳/۸۹۳	۲۳/۵۱	۵۸	۱۸/۰۶	۶/۴۳	۲۳/۰۲۳	۲۳/۰۳	۱۱۰	۵۸/۷۲	۶۴/۲۵	۱۹/۸۳۷	۲۱/۵۲
۳۱	۶۴/۷۴	۵۷/۸۲	۲۳/۸۰۷	۲۳/۲۱	۵۹	۴۱۷/۰۲	۲۴۲	۲۳/۴۲۵	۲۳/۷۱	۱۱۲	۱۰۲/۳۷	۲۷/۸۵	۱۹/۹۹۷	۲۱/۵۶
۳۲	۸۸/۸۲	۴۹/۲۷	۲۳/۲۲۲	۲۳/۹۴	۶۰	۱۱۷/۴۳	۶/۴۳	۲۳/۱۱۷	۲۱/۳۸					
۷۰	۹۹/۳۶	۴۲/۸۳	۲۳/۰۴۲	۲۳/۶۷	۶۲	۱۱۵/۹۳	۲۹/۹۹	۲۳/۰۱۵	۲۱/۰۵					
۷۲	۱۸/۰۶	۰	۲۳/۹۳۳	۲۳/۲۳	۶۶	۵۸/۷۲	۳۸/۵۵	۲۱/۶۱۵	۲۳/۴۶					
۷۳	۹/۰۳	۰	۲۳/۰۵۳	۲۳/۵۶	۶۷	۴۲/۱۶	۱۴/۹۹	۲۱/۹۹۶	۲۰/۰۵					
۷۴	۱۰۲/۳۷	۵۷/۸۲	۲۳/۸۹	۲۳/۲۵	۷۶	۱۰۲/۳۷	۷۷/۰۹	۲۳/۱۳۵	۲۴/۱۹					
۷۵	۷۰/۷۶	۲۳/۵۶	۲۳/۴۸۷	۲۳/۱۵	۷۷	۹۱/۸۳	۵۹/۹۶	۲۳/۰۶۶	۲۳/۰۱					
۱۱۳	۹/۰۳	۰	۲۳/۸۴۷	۲۳/۵۶	۷۸	۱۰۶/۸۸	۵۵/۶۸	۲۳/۲۰۷	۲۳/۴۱					
۱۱۴	۱۲/۰۴	۶/۴۳	۲۳/۴۰۹	۲۳/۶۴	۷۹	۵۸/۷۲	۶۸/۵۴	۲۳/۱۴۴	۲۳/۰۸					
۱۱۵	۳۳/۱۱	۱۴/۹۹	۲۳/۴۲۹	۲۳/۰۸	۸۰	۱۹۵/۷۲	۵۵/۶۸	۲۱/۵۷۸	۲۳/۳۹					
۱۱۷	۳۰/۱	۱۷/۱۳	۲۴/۰۷۳	۲۴/۰۸	۹۷	۲۳/۵۸	۱۹/۲۷	۲۱/۴۹۷	۲۰/۷۱					
					۹۸	۵۱/۱۹	۱۷/۱۳	۲۱/۱۲	۲۳/۴۶					
					۹۹	۶۳/۲۳	۰	۱۹/۰۶۵	۲۰/۹۳					
					۱۱۶	۲۷۷/۰۱	۰	۲۱/۹۸۲	۲۳/۳۶					
					۱۱۸	۴۹/۶۷	۳۲/۱۲	۲۳/۵۵۸	۲۳/۵۷					

جدول (۶): معیارهای مربوط به نحوه پاسخ شبکه عصبی در هر ناحیه برای موارد تست شده

اندیسهای عملکرد	ناحیه ۱			ناحیه ۲			ناحیه ۳		
	روز -۱۰ ساعت ۱۹	روز -۱۹ ساعت ۱۹	روز -۲۵ ساعت ۱۹	روز -۱۰ ساعت ۱۹	روز -۱۹ ساعت ۱۹	روز -۲۵ ساعت ۱۹	روز -۱۰ ساعت ۱۹	روز -۱۹ ساعت ۱۹	روز -۲۵ ساعت ۱۹
MSE	۰/۴۷۳۳	۰/۰۷۶۳	۰/۳۹۴۸	۰/۳۰۹۳	۰/۴۱۲۷	۰/۲۸۹۹	۰/۱۸۴۳	۰/۲۸۸۶	۰/۲۲۵۵
RMSE	۰/۶۸۸	۰/۲۷۶۲	۰/۶۲۸۳	۰/۵۵۶۲	۰/۶۴۲۴	۰/۵۳۸۴	۰/۴۲۹۴	۰/۵۳۷۲	۰/۴۷۴۹
MAE	۱/۰۲۲۸	۰/۴۶۹۶	۱/۱۴۲۸	۰/۸۲۰۲	۰/۹۲۰۳	۰/۷۳۹۱	۰/۹۴۱۲	۱/۰۹۱۳	۰/۸۵۲۵
Min Abs Error	۰/۰۶۵	۰/۰۰۷	۰/۰۷۴	۰/۰۴۳	۰/۰۵۶	۰/۰۶۴	۰/۱۲۵	۰/۱۴۸	۰/۰۲۳
Max Abs Error	۲/۴۹۸	۱/۳۵۹	۲/۴۶۱	۱/۹۲۳	۲/۷۸	۲/۴۷۳	۱/۶۴	۱/۹۷۶	۱/۹۴۱




۶- نتیجه گیری

در این مقاله روشی جدید در پیش‌بینی کوتاه مدت قیمت تراکم گرهی در سیستم‌های قدرت بزرگ با استفاده از شبکه‌های عصبی مصنوعی بهینه شده با الگوریتم ژنتیک پیشنهاد شده است. برای بررسی صحت عملکرد این روش پیشنهادی از سیستم تست ۱۱۸ شینه IEEE استفاده شده است. برای بدست آوردن پایگاه داده مورد نیاز برای آموزش شبکه عصبی، تمام ساعتهای یک دوره ۳۰ روزه انتخاب گردید. سپس معادلات پخش بار بهینه با در نظر گرفتن کلیه قیود موثر حل شد تا قیمت‌های واقعی برای هر شین تعیین شود. در نهایت با تقسیم شبکه به سه ناحیه پیش‌بینی قیمت با استفاده از یک شبکه عصبی برای هر ناحیه، انجام شده است. نتایج شبیه‌سازی نمایانگر عملکرد مناسب روش پیشنهادی در پیش‌بینی قیمت‌های تراکم گرهی و کاهش خطای آن خصوصاً در نقاط جهش قیمت می‌باشد.

مراجع

- [1] N. Amjady, "Day-Ahead Price Forecasting of Electricity Market by a New Fuzzy Neural Network", IEEE Trans. on Power Systems, Vol. 21, No. 2, pp. 888-896, May 2006.
- [2] A. Miranian, M. Abdollahzade, H. Hassani, "Day-ahead Electricity Price Analysis and Forecasting by Singular Spectrum Analysis", IET Gener. Transm. Distrib., Vol. 7, No. 4, pp. 337 – 346, 2013.
- [3] P. Areekul, T. Senjyu, H. Toyama, A. Yona, "Notice of Violation of IEEE Publication Principles A Hybrid ARIMA and Neural Network Model for Short-Term Price Forecasting in Deregulated Market", IEEE Trans. on Power Systems, Vol. 25, No. 1, pp. 524 – 530, 2010.
- [4] M. Olsson, L. Söder, "Modeling Real-Time Balancing Power Market Prices Using Combined SARIMA and Markov Processes", IEEE Trans. on Power Systems, Vol. 23, No. 2, pp 443-450, May. 2008.
- [5] W. Lei, M. Shahidehpour, "A Hybrid Model for Day-Ahead Price Forecasting", IEEE Trans. on Power Systems, Vol. 25, No. 3, pp. 1519 – 1530, 2010.

همچنین منحنی‌های شکل (۱۰) نحوه تغییرات مقادیر قیمت واقعی و پیش‌بینی شده جدول (۶) را نشان می‌دهد. در جدول (۶) مقادیر MSE, RMSE و MAE برای پاسخ شبکه عصبی در هر ناحیه در موارد تست شده ارائه شده است. این مقادیر با استفاده از روابط (۱۲) تا (۱۴) بدست آمده‌اند. همانطور که مشاهده می‌شود عملکرد روش پیشنهادی دارای نتایج بسیار خوبی برای پیش‌بینی قیمت در روزهای تست شده می‌باشد. بر اساس این جدول مقدار حداکثر MAE برابر ۲/۷۸ دلار بر مگوات ساعت بوده است که مربوط به ساعت ۱۹ روز ۱۰ از ناحیه ۲ بوده است. همچنین حداقل MAE برای همه نواحی خیلی کم و در رنج کاملاً قابل قبولی قرار دارد. با بررسی کلیه موارد تست شده مشاهده می‌شود که روش پیشنهادی توانسته است مقدار قیمت را در نقاط جهش قیمت، با دقت قابل قبول و در زمان بسیار کمی در حدود ۹ ثانیه پیش‌بینی کند.



شکل (۱۰): مقادیر واقعی و پیش‌بینی شده قیمت برای ساعت ۱۹ روز ۱۹ در هر ۳ ناحیه سیستم قدرت

- [18] B.-J. Chen, M.-W. Chang, and C.-J. Lin, "Load forecasting using support vector machines: a study on EUNITE competition 2001", IEEE Trans. on Power System, Vol. 19, No. 4, pp. 1821–1830, Nov. 2004.
- [19] M. Shahidehpour, H. Yamin and Z. Li, "Market Operations in electric power systems, Forecasting, Scheduling, and Risk Management", John Wiley & Sons, Inc., Publication, 2002, USA.
- [۲۰] حسین عسگریان ابیانه، حسین شریعتی دهاقان، محمد حسین جاویدی دشت بیاض، فرزاد رضوی، "برنامه ریزی توسعه شبکه انتقال تحت شرایط بازار برق با در نظر گرفتن هزینه برقراری امنیت"، مجله انجمن برق و الکترونیک ایران، سال ششم، شماره دوم، پائیز و زمستان ۱۳۸۸.
- [21] M. T. Hagan and M.B. Menhaj, "Training Feed Forward Networks with the Marquardt Algorithm", IEEE Transaction on Neural Networks, Vol. 5, No. 6, pp. 989-993, pp. 62-62, Nov. 1994.
- [22] http://motor.ece.iit.edu/data/118bus_abreu.xls
- [23] J. Wang, M. Shahidehpour, Z. Li, "Security-Constrained Unit Commitment with Volatile Wind Power Generation", IEEE Trans. on Power Systems, Vol. 23, No. 3, pp. 1319-1327, August 2008.
- [6] H. Mori, A. Awata, "Normalized RBFN with Hierarchical Deterministic Annealing Clustering for Electricity Price Forecasting", IEEE Power Engineering Society General Meeting, pp. 1-7, 2007.
- [7] A. Troncoso, J. Riquelme, J. Riquelme, A. Gómez, and J. L. Martínez, "A comparison of two techniques for next-day electricity price forecasting", in Proc. 13th Int. Conf. Database and Expert Systems Applications, Vol. 2453, Lecture Notes In Computer Science, 2002.
- [8] V. Nanduri, T. K. Das, "A Reinforcement Learning Model to Assess Market Power Under Auction-Based Energy Pricing", IEEE Transactions on Power Systems, Vol. 22, No. 1, pp 85- 95, Feb. 2007.
- [9] J. J. Guo, P. B. Luh, "Improving Market Clearing Price Prediction by Using a Committee Machine of Neural Network", IEEE Trans. on Power Systems, Vol. 19, No. 4, pp. 1867- 1876, Nov. 2004.
- [10] N. Kunwar, K. Yash, R. Kumar, "Area-Load Based Pricing in DSM Through ANN and Heuristic Scheduling", IEEE Trans. on Smart Grid, Vol. 4, No.3, pp. 1275 – 1281, 2013.
- [11] S.N. Pandey, S. Tapaswi and L. Srivastava, "Nodal Congestion Price Estimation in Spot Power Market Using Artificial Neural Network", IET Proc. C, Gener. Transm. Distrib., Vol. 2, No. 2, 2008, pp. 280–290.
- [12] A. Wang, B. Ramsay, "Prediction of System Marginal Price in the UK Power Pool Using Neural Network", Proc. Int. Conf. Neural Network, Vol. 4, pp. 2116-2120, June 1997.
- [13] H.C. Wu, S.C. Chan, K.M. Tsui, H. Yunhe, "A New Recursive Dynamic Factor Analysis for Point and Interval Forecast of Electricity Price", IEEE Trans. on Power Systems, Vol. 28, No. 3, pp. 2352 – 2365, 2013.
- [14] P. Areekul, T. Senjyu, H. Toyama and A. Yona, "A Hybrid ARIMA and Neural Network Model for Short-Term Price Forecasting in Deregulate Market", IEEE Trans. on Power System Vol. 25, No. 1, pp. 524-530, Feb. 2010.
- [15] G. Li, C. C. Liu, C. Mattson and J. Lawarrée, "Day-Ahead Electricity Price Forecasting in a Grid Environment", IEEE Trans. on Power Systems, Vol. 22, No. 1, pp 266- 274, Feb. 2007.
- [16] N. Bigdeli, K. Afshar, N. Amjadi, "Market data analysis and short-term price forecasting in the Iran electricity market with pay-as-bid payment mechanism", Electric Power Systems Research Vol. 79, pp. 888–898, 2009.
- [17] C. P. Rodriguez and G. J. Anders, "Energy price forecasting in the ontario competitive power system market", IEEE Trans. on Power System, Vol. 19, No. 1, pp. 366–374, Feb. 2004.

زیر نویس ها

- ¹ Autoregressive Integrated Moving Average
- ² Seasonal ARIMA
- ³ Generalized Autoregressive Conditional Heteroskedasticity
- ⁴ Market Clearing Price
- ⁵ Adaptive Network-Based Fuzzy Inference System
- ⁶ Weighted Average Price
- ⁷ Minimum Accepted Price
- ⁸ Support Vector Machine
- ⁹ Nodal Congestion Price
- ¹⁰ Large Scale
- ¹¹ Karush-Kuhn-Tucker
- ¹² Shadow Price
- ¹³ Nodal Congestion Price
- ¹⁴ Pool Market
- ¹⁵ Levenberg-Marquardt Back Propagation
- ¹⁶ Performance Index
- ¹⁷ Identify Matrix
- ¹⁸ Mean Square Error
- ¹⁹ Root Mean Square Error
- ²⁰ Mean Absolute Error
- ²¹ Heuristic
- ²² Uniform