

پالایش داده‌های آموزشی شبکه عصبی و بررسی تأثیر آن در کاهش خطای پیش‌بینی کوتاه مدت بار سیستمهای قدرت

امیر مشاری*، اکبر ابراهیمی**، سعید صدری** و محمد ابراهیمی**
دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی اصفهان

(دریافت مقاله: ۱۳۸۶/۱۲/۲۷ - دریافت نسخه نهایی: ۱۳۸۸/۶/۱)

چکیده -

واژگان کلیدی :

Filtering out the Training Data of ANN and Evaluation of Its Effect on Error Reduction in Short-Term Load Forecasting in Power Systems

A. Moshari, A. Ebrahimi, S. Sadri and M. Ebrahimi

Department of Electrical and Computer Engineering, Isfahan University of Technology

Abstract: Occurrence of special events such as overloads, load shedding, interruptions and faults, and shortcomings of operators in an error free manual recording of data are the main sources of anomalous load profiles imposing errors in Artificial Neural Network based Short-Term Load Forecasting (ANNSTLF) systems. In this paper, an ANNSTLF system is properly designed for the real power system of Isfahan Province and used to compare the impacts of filtering out the anomalous data by expert experience, statistical analysis, and a new algorithm based on the Principal Component Analysis (PCA). The results show that filtering out anomalous load-profiles before ANNSTLF can reduce the forecasting error efficiently. It is also shown that the proposed PCA filtering method is simpler in application and faster in response, yielding accurate forecasting results

Keywords: Short-term load forecasting, Artificial neural networks, Data filtering, Principle component analysis.

۱- مقدمه

گرفته، دیده شده است که ۱ درصد افزایش خطای پیش‌بینی بار معادل افزایش ۱۰ میلیون پوند در هزینه تولید سالیانه انرژی برق این کشور است [۱]. همچنین برای ۱۹ شرکت تولید برق مورد مطالعه در آمریکا، هنگامی که محدوده خطای پیش‌بینی کوتاه مدت بار بین ۳٪ تا ۵٪ باشد، هر ۱٪ کاهش خطا معادل ۰/۱ تا ۰/۳ درصد کاهش در هزینه‌های تولید سالیانه این شرکتهاست. به‌عنوان مثال، برای یکی از این شرکتها با متوسط پیک سالیانه ۳۵۰۰۰ مگاوات، با بهبود سیستم پیش‌بینی بار و کاهش ۱/۵ درصدی در خطا، ۷/۶ میلیون دلار در هزینه‌های سالیانه صرفه‌جویی شده است [۲].

در سالهای اخیر، با توجه به رشد چشمگیر کاربرد شبکه‌های عصبی در زمینه‌های مختلف، استفاده از این شبکه‌ها برای حل مسئله پیش‌بینی بار نیز بسیار رواج و نسبت به سایر روشها برتری یافته است [۳]. علت این موضوع قابلیت فوق‌العاده شبکه‌های عصبی در یادگیری روابط پیچیده و غیرخطی است که یافتن چنین روابطی به کمک تکنیکهای قدیمی تر مانند رگرسیون یا سریهای زمانی، بسیار مشکل است. این توانایی، سیستمهای پیش‌بینی بار مبتنی بر شبکه‌های عصبی را قادر به مدل کردن ارتباط میان بار و عوامل مؤثر بر آن مثل شرایط جوی، الگوی مصرف گذشته بار و شرایط زمانی (دوره‌های هفتگی و روزانه، تعطیلات رسمی و آخر

انرژی محور توسعه اقتصادی و اجتماعی در جهان امروز است و انرژی الکتریکی به دلیل خصوصیات ویژه‌اش از سایر انواع انرژی اهمیت بیشتری دارد. تعقیب دقیق بار توسط سیستم تولید انرژی در تمام زمانها یکی از نیازهای اساسی سیستمهای قدرت است. به همین دلیل، پیش‌بینی کوتاه مدت بار در مقطع زمانی یک ساعت تا چند روز آینده در بهره‌برداری اقتصادی، برآورد قابلیت اطمینان و تخصیص ظرفیت ذخیره چرخان و دیگر برنامه‌ریزیهای کوتاه مدت در سیستمهای قدرت کاربرد فراوانی دارد. کیفیت پیش‌بینی کوتاه مدت بار تأثیر قابل توجهی بر بازدهی فرایند تولید انرژی الکتریکی دارد زیرا تعداد زیادی از تصمیمات عملیاتی بر هزینه مانند زمان‌بندی اقتصادی تولید، زمان‌بندی خرید سوخت، ارزیابی امنیت شبکه و برنامه‌ریزی برای خرید و فروش انرژی به پیش‌بینی کوتاه مدت بار وابسته‌اند. همچنین با توجه به حرکت صنعت برق به سمت بازار رقابتی و مطرح شدن بحث تجدید ساختار و خصوصی‌سازی این صنعت در سالهای اخیر، اهمیت پیش‌بینی هرچه دقیقتر بار بیشتر شده است.

بعضی گزارشهای موجود، تأثیر قابل ملاحظه دقت پیش‌بینی بار بر کاهش هزینه‌های سالیانه تولید را ارائه کرده‌اند. از جمله، براساس نتایج مطالعه‌ای که در سال ۱۹۸۵ در انگلستان انجام

به شبکه عصبی است. هر چند در صورت بزرگ بودن مجموعه آموزش و کم بودن داده‌های غیرعادی و پرت می‌توان از تأثیر آن با تقریب خوبی چشمپوشی کرد، اما در مسئله پیش‌بینی کوتاه مدت بار که تعداد پروفایل‌های بار مفید به علت تغییر خصوصیات سیستم قدرت و پروفایل بار در طول زمان معمولاً کم است، وجود چنین داده‌هایی می‌تواند در دسر ساز باشد.

به‌طور کلی داده‌ها یا به عبارت دیگر پروفایل‌های بار غیر عادی را می‌توان به دو دسته تقسیم کرد. دسته اول داده‌های نادرستی‌اند که در اثر عواملی چون ضعف در سیستم ثبت اطلاعات، اشتباهات دستگاه‌های اندازه‌گیری، خطاهای انسانی و بی‌دقتی اپراتورها به وجود آمده‌اند. فراوانی این نوع از داده‌های غیرعادی در کشورهای با ساختار سنتی صنعت برق (مثل ایران)، نسبتاً زیاد است. ضرورت حذف این داده‌های غیرواقعی بدیهی و تأثیر آن در کاهش خطای پیش‌بینی قابل توجه است.



گروه دوم، داده‌هایی هستند که مقادیر واقعی بار مصرفی‌اند اما مربوط به زمانهایی هستند که الگوی بار در اثر بروز شرایط خاص، متفاوت با الگوی نرمال بار است. این شرایط خاص از یکسو می‌تواند بروز حالات اضطراری در سیستم قدرت مانند اضافه بار شدن خطوط و اجبار به قطع آنها، وقایع پیش‌بینی‌نشده و اقدامات اصلاحی پیامد آن، بارزدایی، فروپاشی شبکه و خاموشیهای گسترده باشد و از سوی دیگر می‌تواند در اثر عواملی چون پخش برنامه‌های تلویزیونی پرتعداد، اعتصابات، طوفان و غیره رخ دهد. بنابراین به وجود آمدن این گروه از داده‌های غیر عادی در سیستم‌های قدرت اجتناب‌ناپذیر است و در ساختارهای پیشرفته صنعت برق نیز دیده می‌شوند. ممکن است چنین تصور شود که حذف گروه دوم داده‌های غیرعادی موجب از دست رفتن بخشی از اطلاعات واقعی بار می‌شود ولی باید توجه داشت که زمان وقوع عوامل گفته شده غیرقابل پیش‌بینی و همچنین میزان تأثیر آنها بر الگوی بار بسیار متفاوت است. بنابراین در پیش‌بینی کوتاه مدت بار بهتر است شرایط سیستم قدرت عادی فرض شود و داده‌های غیرعادی از

هفته و . . .) می‌کند. در سالهای اخیر مطالعات بسیاری در زمینه بهبود عملکرد سیستم‌های پیش‌بینی بار مبتنی بر شبکه‌های عصبی صورت گرفته است. از جمله سعی شده است تا با به‌کارگیری تکنیکهایی چون منطق فازی [۴ و ۵]، الگوریتم ژنتیک [۶ و ۷] و روش‌های ابتکاری [۷ و ۸]، میزان خطا در پیش‌بینی بار کاهش یابد و همچنین به‌کارگیری این سیستمها به صورت زمان حقیقی [۹ و ۱۰] و نیز در بازار رقابتی برق [۴ و ۱۱] بررسی شده است، اما کمتر به صحت داده‌های آموزشی شبکه‌های عصبی و تأثیر پالایش آنها در کاهش خطا توجه شده است. این در حالی است که در سیستم‌های پیش‌بینی بار مبتنی بر شبکه‌های عصبی، آموزش دیدن این شبکه‌ها با داده‌های اشتباه می‌تواند سبب یادگیری رابطه‌ای غیر واقعی و در نتیجه افزایش خطا شود.

در این مقاله، مسئله پیش‌بینی کوتاه مدت بار در سیستم قدرت استان اصفهان مورد توجه قرار می‌گیرد و با طراحی یک سیستم پیش‌بینی کننده مناسب براساس شبکه‌های عصبی پیشخور، تأثیر پالایش داده‌های آموزشی بر کاهش خطا بررسی می‌شود. در بخشهای بعدی این مقاله، ضرورت پالایش داده‌ها مطرح و چند روش برای پالایش داده‌ها پیشنهاد می‌شود. در نهایت با معرفی سیستم پیش‌بینی کوتاه مدت بار طراحی شده برای شبکه قدرت مورد نظر، تحلیل و مقایسه نتایج عددی به دست آمده از شبیه سازی روشهای مذکور ارائه خواهد شد.

۲- ضرورت پالایش داده‌ها

وجود داده‌های غیرعادی و پرت در مجموعه داده‌های آموزشی شبکه عصبی پیش‌بینی کننده بار در نگاه اول ممکن است مسئله مهمی تلقی نشود. اما چنین داده‌هایی می‌تواند باعث افزایش چشمگیری در خطای پیش‌بینی بار شود زیرا رابطه الگوی بار و عوامل مؤثر بر آن به شکل یک تابع به شدت غیر خطی است و مخدوش شدن الگوی بار به معنای از دست رفتن این رابطه و در واقع آموزش دادن یک رابطه غلط



شکل ۱- نمونه پروفایلهای بار عادی مربوط به تیر ماه ۸۴

شکل ۲- نمونه پروفایلهای بار غیرعادی مربوط به تیر ماه ۸۳

مبنای استفاده از تجربه خبره و مقایسه آماری معرفی و سپس، روش جدیدی بر مبنای تحلیل مؤلفه اصلی ارائه می شود.

مجموعه داده های آموزشی حذف شود.

با بررسی های اولیه در پروفایلهای بار ثبت شده در سیستم قدرت استان اصفهان در فاصله زمانی سالهای ۱۳۸۱ تا ۱۳۸۴ مشخص شد که تعداد قابل توجهی از آنها (در حدود ۲۰ درصد) در رده پروفایلهای بار غیر عادی قرار می گیرند. وجود پرشهای شدید چند صد مگا وات، و حتی بار منفی (!؟) ضرورت پالایش این داده ها را قبل از آموزش شبکه عصبی پیش بینی کننده بار آشکار می سازد.

۳- پالایش داده ها بر مبنای تجربه خبره

مؤثرترین روش تشخیص داده های غیرعادی استفاده از شناخت و تجربه خبره است. چنین شناختی با مطالعه، تحلیل و بررسی تفصیلی پروفایلهای بار روزهای مختلف فراهم می شود. در شکل (۱) نمونه متداول پروفایلهای بار عادی سیستم قدرت استان اصفهان مربوط به یک هفته در تیرماه ۱۳۸۴ دیده می شود. شباهت زیاد پروفایلهای بار در روزهای شنبه تا چهارشنبه، تفاوت کم روز پنجشنبه با آنها و تفاوت بیشتر روز جمعه کاملاً آشکار است. اکثریت قابل توجهی از پروفایلهای بار روزانه از این ویژگی، کم و بیش، برخوردارند.

یکی از محدود روشهایی که در سالهای اولیه برای پالایش داده ها در پیش بینی کوتاه مدت بار استفاده شده است، روش فیلتر کالمن است. این روش در شرایط بار عادی به خوبی کار می کند [۱۴]، اما وقتی تغییرات غیر طبیعی مثل پروفایلهای بار غیر عادی وجود دارد، به نتایج نادرست منجر می شود. عملیات ریاضی سنگین، زمان بر بودن، عدم دقت ذاتی و ناپایداری عددی از دیگر نواقص این روش محسوب می شود [۱۵].

در شکل (۲) نمونه هایی از پروفایلهای بار غیرعادی در روزهای پنجشنبه و جمعه مربوط به تیرماه ۱۳۸۳ دیده می شود. غیرعادی بودن پروفایل بار روز جمعه کاملاً مشهود است و به نظر می رسد این پروفایل بار مربوط به دسته اول پروفایلهای غیرعادی باشد. شکل (۳) پروفایلهای بار غیرعادی در روزهای سه شنبه و جمعه در مردادماه سال ۱۳۸۳ را نشان می دهد. پروفایل بار روز جمعه به نظر می رسد به دسته دوم پروفایلهای غیرعادی تعلق داشته باشد و افت بسیار زیاد بار در آن می تواند

لازم به ذکر است که مقصود از پروفایلهای بار غیرعادی پروفایلهای مربوط به تعطیلات رسمی نیست. زیرا این گروه از پروفایلهای بار هر چند الگویی متفاوت با روزهای عادی دارند ولی هر ساله تکرار می شوند و به طور کلی در مسئله پیش بینی بار به صورت جداگانه در نظر گرفته می شوند. در ادامه، ابتدا دو روش اصلی پالایش داده های آموزشی بر

شکل ۱، $n=1, \dots, 24$ است به صورت رابطه (۱) است:

$$\bar{L} = \frac{1}{24} \sum_{n=1}^{24} L[n] \quad (1)$$

انحراف استاندارد که در واقع ریشه دوم واریانس است برای دنباله فوق از رابطه (۲) به دست می آید:

$$S_L = \sqrt{\frac{1}{24} \sum_{n=1}^{24} (L[n] - \bar{L})^2} \quad (2)$$

برای دو دنباله محدود $a[n]$ و $b[n]$ که تنها در بازه $n=0, 1, \dots, N-1$ مقدار دارند، می توان دنباله همبستگی متقابل^۱ را به شکل رابطه (۳) تخمین زد [۱۳]:

$$\hat{R}_{ab}(m) = \begin{cases} \sum_{n=0}^{N-m-1} a[n+m].b^*[n] & m \geq 0 \\ \hat{R}_{ab}^*(-m) & m < 0 \end{cases} \quad (3)$$

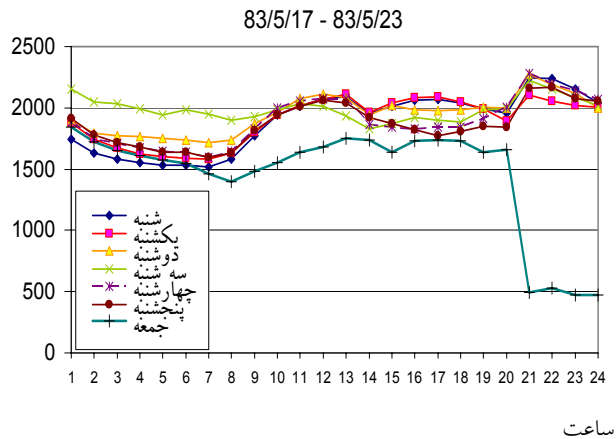
دنباله فوق تنها در $-(N-1) \leq m \leq N-1$ پاسخ غیر صفر خواهد داشت. بزرگترین مقدار دنباله همبستگی متقابل به عنوان همبستگی میان دو دنباله $a[n]$ و $b[n]$ تعریف می شود.

بنابراین برای پروفایلهای بار شبانه روزی، بزرگترین مقدار دنباله همبستگی متقابل مربوط به آنها به عنوان میزان همبستگی یا شباهتشان به یکدیگر در نظر گرفته می شود. به علت دوره های هفتگی در مصرف بار، شکل پروفایل بار روزهای مشابه (مثلاً شنبه ها) در هفته های مختلف شباهت زیادی به یکدیگر دارد و این شباهت میان روزهای مختلف هفته (مثلاً شنبه ها به پنجشنبه ها) کمتر است. بنابراین می توان از مقدار خودهمبستگی روزهای هفته (مثلاً همبستگی میان شنبه های هفته های مختلف با یکدیگر) به عنوان یک ویژگی اساسی آنها استفاده کرد. برخی از پروفایلهای بار غیرعادی که از نظر شکل با پروفایلهای عادی متفاوت اند، میزان خودهمبستگی کمتری نسبت به پروفایلهای بار عادی خواهند داشت.

۴-۱- شناسایی داده های پرت بر اساس مقایسه

با توجه به دوره های فصلی در الگوی مصرف بار، مشخصات اساسی پروفایلهای بار در فصلهای گوناگون متفاوت

مگا



شکل ۳- نمونه پروفایلهای بار غیرعادی مربوط به مرداد ماه ۸۳

ناشی از وقوع یک خاموشی گسترده باشد.

در این روش پالایش، پروفایلهای غیرعادی از طریق مقایسه با پروفایلهای عادی، که ویژگیهایی مورد انتظار و نرمال دارند، به صورت شهودی و بر مبنای تجربه خیره تشخیص داده می شوند و سپس از مجموعه داده ها حذف می شوند. اما استفاده از چنین روشی برای شناسایی داده های غیر عادی و پالایش آنها، در عین حال که می تواند مؤثر باشد، سیستماتیک و ساده نیست و پیاده سازی آن در یک سیستم قدرت واقعی به علت تعدد نشانه های غیر عادی بودن بار بسیار پیچیده و وقت گیر خواهد بود.

۴-۲ پالایش داده ها بر مبنای مقایسه آماری

با مقایسه آماری پروفایلهای بار می توان به معیارهایی برای شناسایی داده های غیرعادی دست یافت. با بررسیهای مفصل بر روی پروفایلهای بار ۲۴ ساعته مشخص شد که هر پروفایل بار را می توان به کمک ۳ معیار اساسی به صورت منحصر به فرد شناسایی کرد. این سه معیار اساسی میانگین، انحراف استاندارد و همبستگی اند که به ترتیب معرف متوسط مصرف شبانه روزی بار، میزان پراکندگی بار شبانه روزی حول مقدار متوسط مصرف و شباهت هر پروفایل بار از نظر شکل به سایر پروفایلها می باشد.

تعریف میانگین برای پروفایل بار که در واقع دنباله ای به

۵-۱- تبدیل DKL^۲

در این تبدیل هر دنباله بر حسب یکی سری بردار ارتوگونال نمایش داده می‌شود. ثابت می‌شود که اگر این بردارها، بردارهای ویژه ماتریس همبستگی^۳ دنباله‌ها بوده و میانگین هر یک از دنباله‌ها صفر باشد، مؤلفه‌های دنباله تصویر شده، نسبت به یکدیگر ناهمبسته‌اند [۱۳]. بردار N بعدی $x[n]$ بر حسب بردارهای پایه ارتوگونال ϕ_i به شکل زیر نمایش داده می‌شود:

$$X = \Phi K = \begin{bmatrix} \phi_1 & \phi_2 & \dots & \phi_N \end{bmatrix} \begin{bmatrix} k_1 \\ k_2 \\ \vdots \\ k_N \end{bmatrix} \quad (4)$$

بردارهای ϕ_i (ستونهای ماتریس Φ) نسبت به هم ارتوگونال‌اند، لذا:

$$\phi_i^* \phi_j = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases} \quad (5)$$

بنابراین می‌توان نتیجه گرفت:

$$K = \begin{bmatrix} \phi_1^* \\ \phi_2^* \\ \vdots \\ \phi_N^* \end{bmatrix} X = \Phi^* X \quad (6)$$

بردارهای ϕ_i ، بردار ویژه‌های ماتریس همبستگی دنباله‌هایی مانند X است که توسط تبدیل DKL به فضای جدید تصویر می‌شوند. برای k دنباله مانند x_i و با بعد N ، ماتریس همبستگی به صورت زیر تخمین زده می‌شود:

$$\hat{R}_X = \frac{1}{k} X^* X, X = \begin{bmatrix} x_1[0] & x_1[1] & \dots & x_1[N-1] \\ x_2[0] & x_2[1] & \dots & x_2[N-1] \\ \vdots & \vdots & \ddots & \vdots \\ x_k[0] & x_k[1] & \dots & x_k[N-1] \end{bmatrix} \quad (7)$$

بنابراین بردارهای پایه فضا در تبدیل DKL یعنی ϕ_i ها به صورت زیر تعریف می‌شوند:

است. در روش پالایش مقایسه‌ای، ابتدا برای کل پروفایل‌های بار هر روز هفته در هر فصل، متوسط فصلی هر یک از ۳ معیار اساسی مطرح شده در روابط (۱) تا (۳) محاسبه می‌شود. سپس مقدار میانگین، انحراف استاندارد و خودهمبستگی پروفایل بار هر روز با میانگین فصلی این معیارها یا به عبارت دیگر با الگوی فصلی مقایسه می‌شود. در صورتی که مقدار این ۳ معیار در محدوده‌ای مجاز نسبت به الگوی فصلی قرار داشته باشد این پروفایل بار پروفایل بار عادی و در غیر این صورت غیرعادی تلقی شده و حذف می‌شود.

به عنوان مثال برای بررسی عادی یا غیرعادی بودن پروفایل بار روز شنبه $۸۴/۲/۳$ مقدار ۳ معیار اساسی برای آن محاسبه و با الگوی فصلی که با متوسط‌گیری از این معیارها برای تمام شنبه‌های فصل بهار به دست می‌آید مقایسه می‌شود.

پارامترهای این روش که عبارت است از محدوده‌های مجاز تغییرات نسبت به الگوی فصلی، می‌بایست نسبت به سالی که پروفایل‌های بار آن بررسی می‌شود مستقل باشد. در غیر این صورت این روش کلیت خود را از دست خواهد داد و برای هر سال می‌بایست دوباره محدوده‌های مجاز را تعیین کنیم. از میان ۳ معیار اساسی پروفایل بار، تنها میانگین مصرف بار تغییرات سالانه قابل اعتنایی دارد و سایر معیارها با توجه به کند بودن تغییراتشان معمولاً هر سال تکرار می‌شوند. بنابراین در این روش به جای میانگین خالص مصرف بار، از مقدار تقسیم شده آن به میانگین مصرف سالیانه بار استفاده می‌شود.

۵- ارائه روش جدیدی در پالایش داده‌ها بر مبنای

تحلیل مؤلفه اصلی

در این بخش، روشی برای پالایش داده‌ها بر مبنای تحلیل مؤلفه اصلی معرفی و پیشنهاد می‌شود. در این روش یک دسته دنباله به دستگاه مختصات دیگری تصویر می‌شوند که در آن دستگاه، بردارهای با ویژگیهای مشترک، در نزدیکی یک محور مختصات قرار می‌گیرند، به طوری که مؤلفه متناظر با آن محور بسیار بزرگتر از دیگر مؤلفه‌ها خواهد شد.

جدول ۱- متوسط مقدار PCR برای پروفایلهای بار عادی و غیرعادی روش پالایش دستی

پروفایلهای غیرعادی	پروفایلهای عادی	PCR
٪۴۷	٪۶۳/۴	شنبه
٪۴۰/۲	٪۵۷/۹	یکشنبه
٪۴۲/۲	٪۵۸/۶	دوشنبه
٪۳۹/۳	٪۵۸/۳	سه شنبه
٪۴۰/۳	٪۵۸	چهارشنبه
٪۳۰/۳	٪۵۳/۵	پنجشنبه
٪۲۳/۲	٪۴۵/۶	جمعه

مقدار PCR برای پروفایلهای بار عادی و غیرعادی تشخیص داده شده بر مبنای تجربه خبره را در جدول (۱) مشاهده می کنید. همان طور که ملاحظه می شود نسبت مؤلفه اصلی به کل مؤلفه ها در تبدیل پروفایلهای بار عادی بزرگتر از تبدیل پروفایلهای بار غیرعادی است.

۵-۳- شناسایی پروفایلهای غیر عادی

برای پالایش داده ها به کمک تبدیل DKL، روشی به نام الگوریتم PCA^۵ طراحی و پیشنهاد می شود. در این الگوریتم تنها به یک نمونه الگوی بار عادی برای هر روز هفته نیاز است که به راحتی و با مشاهده پروفایلهای بار قابل حصول است. این ۷ پروفایل بار، پروفایلهای بار مرجع نامیده می شوند. ابتدا این پروفایلهای بار مرجع، نرمالیزه می شود به طوری که میانگین هر یک از آنها صفر باشد. سپس بر اساس روابط ۴ تا ۸، ماتریس همبستگی این ۷ دنباله (پروفایلهای بار مرجع) تخمین زده شده و بردارهای ویژه این ماتریس محاسبه می شود. این بردارها، پایه های اولیه (مرجع) برای انجام تبدیل DKL خواهند بود. برای پالایش یک مجموعه داده شامل پروفایلهای بار عادی و غیرعادی، از پروفایل اول به ترتیب، بردار تبدیل شده و پارامتر PCR آن بردار، به کمک پایه های مرجع محاسبه می شود. با مقایسه این مقدار با PCR مرجع هر روز هفته، در صورتی که PCR این روز در محدوده مجاز نسبت به PCR مرجع قرار داشت آن روز را به عنوان روز عادی تلقی کرده و آن را به جای

$$R_x \phi_i = \lambda_i \phi_i, \quad i = 1, 2, \dots, N \quad (8)$$

اما نکته اصلی در این روش این است که اگر این k دنباله به صورت m دسته باشند که دنباله های موجود در هر دسته خواص کاملاً مشابهی دارند ($m < N$)، ماتریس همبستگی آنها یعنی R_x مقدار ویژه عمده خواهد داشت و سایر مقادیر ویژه ($N-m$ مقدار ویژه) به مراتب کوچکتر از این m مقدار ویژه اصلی هستند.

۵-۲- نسبت مؤلفه اصلی

با انجام تبدیل DKL، دیده می شود که برای بردارهای تصویر شده پروفایلهای بار عادی، نسبت مؤلفه اصلی به سایر مؤلفه ها بزرگتر از این نسبت برای پروفایلهای بار غیرعادی می باشد. به عبارت دیگر تبدیل DKL، پروفایلهای بار غیرعادی را پراکنده تر از پروفایلهای بار عادی تصویر می کند. البته باید توجه شود که برای پروفایلهای غیرعادی نیز تبدیل به کمک پایه ها یا بردار ویژه های به دست آمده از پروفایلهای عادی انجام می شود. برای مقایسه دنباله های مختلف، برای پروفایل تصویر شده $PT[n]$ که برداری ۲۴ تایی است، معیار PCR^۴ به صورت زیر تعریف می شود:

$$PCR = \frac{|PC|}{\sum_{n=1}^{24} |PT[n]|} \times 100 \quad (9)$$

که در آن PC مؤلفه اصلی (عمده) بردار $PT[n]$ است. متوسط

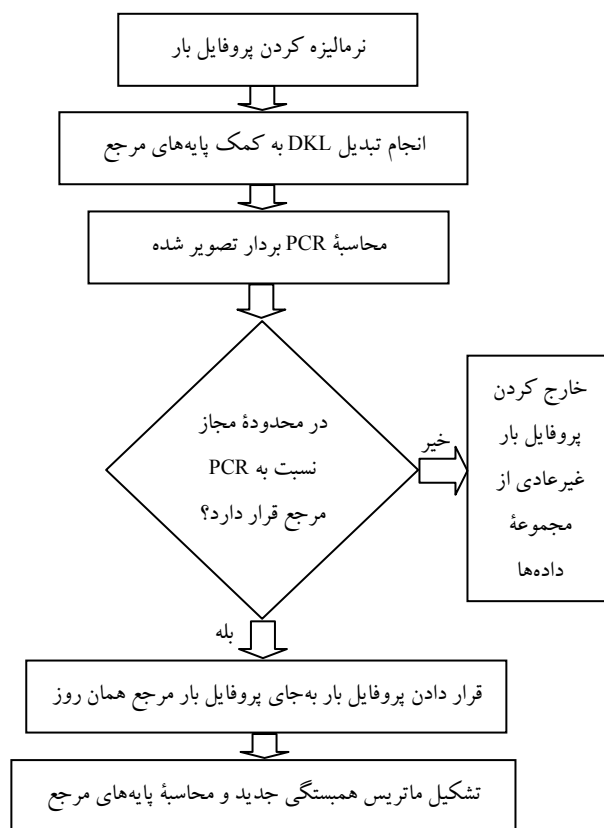
۶- نتایج شبیه‌سازی

برای تحلیل روش پیشنهادی در شناسایی پروفایل‌های بار روزهای غیر عادی و بررسی تأثیر آنها در کاهش خطا، نیاز به طراحی یک سیستم پیش‌بینی کننده بار برای سیستم قدرت مورد نظر بر مبنای شبکه‌های عصبی است. در این بخش پس از معرفی سیستم طراحی شده مذکور، نتایج به‌دست آمده از شبیه‌سازیهای مختلف ارائه و تحلیل می‌شود.

۶-۱- طراحی سیستم پیش‌بینی کوتاه مدت بار شبکه قدرت اصفهان

برای پیش‌بینی بار در هر سیستم قدرت، با توجه به ویژگیهای فیزیکی و مشخصات خاص آن سیستم، باید شبکه عصبی مناسبی طراحی کرد. به این منظور، ابتدا یک سیستم پیش‌بینی کوتاه مدت بار مبتنی بر شبکه‌های عصبی پیشخور براساس اطلاعات دریافتی از مراکز دیسپاچینگ برق منطقه‌ای و اداره هواشناسی استان اصفهان طراحی شد. این اطلاعات شامل میزان مصرف بار کل استان اصفهان، به غیر از بار مصرفی فولاد مبارکه و ذوب آهن اصفهان، به صورت ساعت به ساعت و همچنین حداکثر، حداقل و متوسط دمای شبانه روزی در ۴ شهر اصفهان، کاشان، خور و داران به نمایندگی از ۴ منطقه آب و هوایی متفاوت این استان، در خلال سالهای ۸۱ تا ۸۴ می‌باشد. برای طراحی این سیستم از اطلاعات سالهای ۸۱ تا ۸۳ به عنوان داده‌های آموزشی و از اطلاعات سال ۸۴ برای بررسی میزان اعتبار مدل و سنجش خطا استفاده و با انجام آزمایشات تحلیل حساسیت بر روی پارامترهای مختلف شبکه عصبی، حالات بهینه و مقادیر مطلوب انتخاب شده است.

سیستم نهایی شامل یک شبکه عصبی پرسپترون ۳ لایه است. تعداد نوروهای لایه‌های ورودی، پنهان و خروجی این شبکه به ترتیب، ۳۰، ۴۰ و ۲۴ نرون است. ورودیهای شبکه شامل بار ۲۴ ساعته روز قبل ($L_k[n]$, $n=1, \dots, 24$)، حداکثر، حداقل و متوسط دمای ترکیبی روز قبل (T_k) و پیش‌بینی حداکثر، حداقل و متوسط دمای ترکیبی روز بعد (\hat{T}_{k+1})



شکل ۴- نمودار گردش الگوریتم پالایش PCA

پروفایل بار مرجع آن روز قرار می‌دهیم. بدین ترتیب همواره جدیدترین پروفایل‌های بار عادی، مبنای تبدیل قرار می‌گیرند. این امر سبب می‌شود که تأثیر منفی تغییر مشخصات پروفایل بار در طول فصلها و ماههای مختلف بر دقت این روش پالایش تا حد امکان کاهش یابد.

پارامتر PCR مشخصه هر روز هفته را می‌توان معادل PCR پروفایل‌های مرجع، در هر مرحله قرار داد. اما روش مناسبتر و بهتر این است که ابتدا PCR برای کل مجموعه داده‌ها (بدون در نظر گرفتن عمل پالایش) محاسبه شود. توجه شود که در این مرحله از آنجا که پالایش صورت نمی‌گیرد پروفایل‌های مرجع اولیه به‌روز نمی‌شوند و بنابراین به‌ناچار تبدیل برای تمام روزها براساس همان پروفایل‌های مرجع اولیه انجام می‌شود. سپس از این مقادیر متوسط‌گیری شده و به عنوان PCR مشخصه هر روز هفته قرار داده می‌شود. در شکل (۴) نمودار گردش روش PCA را مشاهده می‌کنید.

جدول ۲- نتایج پالایش مقایسه‌ای در سیستم قدرت اصفهان

پالایش خبره	پالایش مقایسه‌ای	محدوده مجاز
...	٪۲۵	\bar{L} در ایام نوروز
...	٪۱۵	\bar{L} در سایر روزها
...	٪۲۰	S_L در بهار و پاییز
...	٪۱۵	S_L در تابستان و زمستان
...	٪۸	خودهمبستگی در تمام فصول
۷۰	۶۵	تعداد داده‌های غیر عادی در سال ۸۱
۶۷	۵۷	تعداد داده‌های غیر عادی در سال ۸۲
۸۰	۷۸	تعداد داده‌های غیر عادی در سال ۸۳
۴۷	۴۱	تعداد داده‌های غیر عادی در سال ۸۴

است. مقصود از دمای ترکیبی، ترکیب وزن‌دار دمای ۴ شهر مذکور است. خروجی شبکه عصبی نیز بار ۲۴ ساعته روز بعد خواهد بود.

توابع تبدیل لایه‌های پنهان و خروجی این شبکه از نوع سیگموئید است که برای یک نورون با ورودی n و خروجی a ، به شکل زیر است:

$$a = \frac{1}{1 + e^{-n}} \quad (9)$$

برای آموزش شبکه عصبی از الگوریتم گرادیان مزدوج^۷ به روش پولاک-ریبری^۸ استفاده شده است که مشابه روش پس انتشارخطای استاندارد بوده اما سرعت انجام آن به مراتب بیشتر است [۱۲]. همچنین از آنجا که در آموزش شبکه‌های عصبی پیشخور به‌خصوص در هنگام کمبود داده‌های آموزشی احتمال مواجهه با فرارازش^۹ و افزایش خطا وجود دارد، از الگوریتم توقف زودرس^{۱۰}

برای جلوگیری از بروز این مشکل استفاده شده است [۱۲].

۶-۲- شناسایی داده‌های غیرعادی

پس از طراحی سیستم پیش‌بینی کننده بار برای سیستم قدرت مورد نظر، ابزار مناسب برای بررسی اثر پالایش داده‌ها به روشهای مختلف پیشنهادی فراهم می‌شود.

۶-۲-۱- نتایج پالایش خبره

همان‌طور که در بخش (۳) آمد، پالایش خبره از مؤثرترین روشهاست که بر اساس تجربه خبره و با مطالعه تفصیلی پروفایلهای بار صورت می‌پذیرد. با بررسیهای به‌عمل آمده، از میان ۱۳۷۲ پروفایل بار شبانه‌روزی (۲۴ ساعته) مربوط به شبکه قدرت اصفهان که در اختیار ما قرار داده شد، ۲۸۱ مورد آن دارای مشخصات غیرعادی تشخیص داده شدند. این داده‌های غیر عادی با مقایسه شهودی پروفایلهای بار روزهای مختلف یا به عبارت دیگر به صورت دستی شناسایی شده‌اند. این پروفایلهای غیرعادی دارای مشکلاتی از قبیل وجود پرشهای چندصد مگاواتی در دو ساعت پایانی، وجود مصرف بار بسیار کم یا بسیار زیاد در برخی ساعات، عدم تطابق با الگوی نرمال بار مثل نداشتن پیک روز یا پیک شب در ساعات مورد انتظار و غیره‌اند. مسلماً وجود این تعداد داده غیرعادی در مجموعه داده‌ها (بیش از ۲۰٪) که با توجه به ساختار سنتی صنعت برق در ایران امری محتمل است، مسئله آموزش شبکه عصبی را با مشکل جدی مواجه می‌کند و خطای پیش‌بینی کوتاه مدت بار را افزایش می‌دهد. جدول (۲) تعداد پروفایلهای غیرعادی تشخیص داده شده به این روش در داده‌های ثبت شده سیستم قدرت استان اصفهان، را برای سالهای مختلف نشان می‌دهد. همان‌طور که خواهیم دید، پالایش داده‌ها به این روش بیشترین تأثیر را در کاهش خطا داشته است.

۶-۲-۲- نتایج پالایش مقایسه‌ای

چنانچه در بخش (۴) دیده شد در روش پالایش مقایسه‌ای

جدول ۳- نتایج پالایش PCA در سیستم قدرت اصفهان

داده‌های غیرعادی پالایش دستی	داده‌های غیرعادی پالایش PCA	حداقل PCR مجاز	متوسط PCR کل	
۲۷	۳۳	٪۵۳/۳۱	٪۶۱/۳۱	شنبه
۳۷	۴۶	٪۵۵/۳۴	٪۶۳/۳۴	یکشنبه
۴۱	۴۹	٪۵۳/۴۵	٪۶۱/۴۵	دوشنبه
۴۰	۴۷	٪۵۴/۶۴	٪۶۲/۶۴	سه‌شنبه
۵۴	۵۰	٪۵۴/۱۳	٪۶۲/۱۳	چهارشنبه
۳۶	۴۲	٪۴۸/۵۷	٪۵۶/۵۷	پنجشنبه
۴۶	۴۳	٪۲۸/۹۶	٪۳۶/۹۶	جمعه

در جدول (۲) محدوده‌های مجاز به‌دست آمده برای پروفایل‌های بار سیستم قدرت اصفهان آورده شده است. شایان ذکر است که برای عمومیت بیشتر روش، از معیار اعتبار ۲ صرف‌نظر شده و تنها از معیار اعتبار ۱ برای بررسی مناسب بودن محدوده‌ها کمک گرفته شده است. در این جدول همچنین تعداد پروفایل‌های غیرعادی تشخیص داده‌شده برای سال‌های ۸۱ تا ۸۴ برای هر دو روش پالایش تجربه‌خبره و مقایسه‌ای آورده شده است.

۳-۲-۶- نتایج پالایش PCA


در بخش (۵) گفته شد که برای تعیین PCR مشخصه هر روز هفته بهتر است ابتدا PCR تمام روزها (اعم از روزهای با پروفایل بار عادی و روزهای با پروفایل بار غیرعادی) تعیین شده و سپس از آنها متوسط‌گیری شود. در جدول (۳) مقدار PCR مشخصه هر روز هفته به این روش نشان داده شده است. چنانچه دیده می‌شود این مقدار تقریباً برابر PCR روزهای عادی در روش پالایش خبره (مندرج در جدول ۱) است. همچنین در این جدول نتایج پالایش به روش PCA برای پروفایل‌های بار در سیستم قدرت مورد نظر نشان داده شده است. در اینجا محدوده مجاز تغییرات نسبت به PCR مرجع ۸٪ در نظر گرفته شده است که به روش سعی و خطا به‌دست آمده و به‌طریقی که در قسمت پالایش مقایسه‌ای گفته شد اعتبار آن بررسی شده است.

۳-۶- نتایج پالایش داده‌ها در کاهش خطای پیش‌بینی بار


در این قسمت به بررسی میزان بهبود ایجاد شده در دقت پیش‌بینی بار در صورت انجام پالایش داده‌ها می‌پردازیم. چنانکه گفته شد ابتدا شبکه عصبی طراحی شده برای پیش‌بینی بار در سیستم قدرت استان اصفهان، به وسیله اطلاعات مربوط به بار و دما در خلال سال‌های ۸۱ تا ۸۳ آموزش داده شده و سپس بار ۲۴ ساعته برای تمام روزهای سال ۸۴ پیش‌بینی و میزان خطا اندازه‌گیری می‌شود.

برای هر فصل ۳ محدوده مجاز تعریف می‌شود. با توجه به تعداد معیارها (۳ معیار برای هر فصل)، انتخاب محدوده‌های مجاز در این روش تا حدودی مشکل است. این محدوده‌ها از طریق سعی و خطا و تجربیات خبره به‌دست می‌آیند. همچنین برای به‌دست آوردن محدوده‌های مناسب به روش سعی و خطا احتیاج به بررسی اعتبار محدوده‌ها در هر گام داریم. بدین منظور ۲ معیار اعتبار در نظر گرفته می‌شود که در صورتی که هر ۲ معیار برآورده شدند محدوده‌های تعیین شده است خواهند بود. معیار اعتبار نخست قرار گرفتن پروفایل‌های به شدت غیر عادی در خارج از محدوده‌های تعیین شده است. برای بررسی این معیار می‌توان از پروفایل‌های به شدت مخدوش که شناسایی آنها در مجموعه داده‌ها به سادگی امکانپذیر باشد و نیاز زیادی به تجربه خبره نداشته باشد استفاده کرد و یا الگوهای بار نرمال را به صورت دستی مخدوش کرده و از آنها استفاده کرد.


معیار اعتبار دوم بررسی تصادفی تعدادی از پروفایل‌هایی که در محدوده‌های تعیین شده قرار نمی‌گیرند یا به عبارت دیگر غیرعادی تشخیص داده می‌شوند، به کمک تجربه خبره است. وابستگی به تجربه و فرد خبره از نقاط ضعف معیار دوم است که خودکار بودن این روش را زیر سؤال می‌برد.




شکل ۶- متوسط MAPE پیش‌بینی بار سال ۸۴ در حالت پالایش تجربه خبره



شکل ۵- متوسط MAPE پیش‌بینی بار سال ۸۴ بدون پالایش داده‌ها



شکل ۸- متوسط MAPE پیش‌بینی بار سال ۸۴ در حالت پالایش PCA



شکل ۷- متوسط MAPE پیش‌بینی بار سال ۸۴ در حالت پالایش مقایسه‌ای

است که برای رفع وابستگی پیش‌بینیها به وزنهای اولیه شبکه عصبی، عملیات آموزش و پیش‌بینی بار برای هر روز ۱۰ بار و با وزنهای اولیه تصادفی تکرار شده و از نتایج میانگین گرفته شده است.

در جدول (۴) به‌طور خلاصه متوسط خطای پیش‌بینی بار شبکه قدرت اصفهان برای تمام روزهای سال ۸۴ برای حالات بدون پالایش داده‌ها، پالایش خبره، پالایش مقایسه‌ای و پالایش PCA آورده شده است. همان‌طور که دیده می‌شود پالایش داده‌های اولیه و حذف پروفایل‌های بار غیرعادی و پرت می‌تواند بیش از ۱٪ خطای پیش‌بینی بار را کاهش دهد که با توجه به آنچه در مقدمه آورده شد، چنین بهبودی می‌تواند موجب صرفه‌جویی زیادی در هزینه‌های بهره‌برداری از سیستم قدرت

برای محاسبه مقدار خطای پیش‌بینی بار از معیار درصد میانگین قدر مطلق خطا^{۱۱} یا MAPE استفاده شده است. در صورتی که مقدار واقعی بار ۲۴ ساعته با $L[n], n=1,2,\dots,24$ و مقدار بار پیش‌بینی شده برای ساعات مختلف با $\hat{L}[n], n=1,2,\dots,24$ نشان داده‌شود، میزان خطای پیش‌بینی بار از رابطه زیر محاسبه می‌شود:

$$E_{MAPE} = \frac{1}{24} \sum_{n=1}^{24} \left| \frac{L[n] - \hat{L}[n]}{L[n]} \right| \times 100 \% \quad (10)$$

در شکل‌های ۵ تا ۸ متوسط خطای پیش‌بینی بار شبکه قدرت اصفهان برای تمام روزهای سال ۸۴ و به تفکیک روزهای هفته، به ترتیب برای حالات بدون پالایش داده‌ها، پالایش خبره، پالایش مقایسه‌ای و پالایش PCA آورده شده است. شایان ذکر

جدول ۴- متوسط MAPE پیش‌بینی بار در سال ۸۴ برای روش‌های مختلف پالایش داده‌ها

نام روش	متوسط MAPE
حالت پالایش نشده	۴۶/۴٪
روش پالایش تجربه خیره	۳۱/۶٪
روش پالایش مقایسه‌ای	۳۴/۵٪
روش پالایش PCA	۳۴/۷٪

شود. روش پالایش تجربه خیره با وجود آنکه بیشتر از دو روش دیگر دقت پیش‌بینی بار را افزایش می‌دهد اما به‌علت اینکه بسیار وقتگیر و غیر سیستماتیک است و نیاز زیادی به تجربه خیره دارد چندان توصیه نمی‌شود.

از میان دو روش پالایش مقایسه‌ای و پالایش PCA که تقریباً کارایی یکسانی در کاهش خطا دارند، روش PCA چنانکه گفته شد در عمل بسیار سریعتر است و همچنین پارامترهای این روش که باید توسط کاربر تنظیم شوند بسیار کمتر از روش مقایسه‌ای است. همچنین این روش برای اجرا به صورت روزانه مناسبتر است و نیاز به الگوی فصلی ندارد.

۷- نتیجه‌گیری

یکی از مشکلات پیش‌بینی کوتاه مدت بار در سیستم‌های قدرت که کمتر به‌طور جدی مورد توجه قرار گرفته است، وجود داده‌های پرت و غیرعادی در بین اطلاعات مربوط به بار شبانه‌روزی این سیستم‌هاست، که موجب افزایش خطای پیش‌بینی و در نتیجه افزایش شدید هزینه بهره‌برداری از سیستم قدرت می‌شود. در این مقاله، پیش‌بینی کوتاه مدت بار در سیستم قدرت استان اصفهان مورد توجه قرار گرفت. با بررسی‌های اولیه در پروفایل‌های بار ثبت شده در سیستم مذکور در فاصله زمانی سالهای ۱۳۸۱ تا ۱۳۸۴ مشخص شد که در حدود ۲۰ درصد از آنها در رده پروفایل‌های بار غیر عادی قرار می‌گیرند. وجود پرش‌های شدید چند صد مگاواتی، و حتی بار منفی (!؟) ضرورت پالایش این داده‌ها قبل از آموزش شبکه

عصبی پیش‌بینی کننده بار را مشخص کرد.

به این منظور، ابتدا یک سیستم پیش‌بینی کننده بار مناسب برای سیستم قدرت مورد نظر بر مبنای شبکه‌های عصبی پیشخور طراحی و ابزار لازم برای انجام این مطالعات فراهم شد. سپس دو روش اصلی پالایش داده‌های آموزشی بر مبنای استفاده از تجربه خیره و مقایسه آماری مورد استفاده، و نیز روش پالایش جدیدی مبتنی بر تحلیل مؤلفه اصلی (PCA) براساس تبدیل کارهونن لائو^{۱۲} گسسته پیشنهاد شد. در این روش تنها یک مؤلفه برای شناسایی هر دسته از پروفایل‌های بار کفایت می‌کند و در نتیجه می‌تواند با سرعت و سهولت بسیار زیادی نسبت به دیگر روش‌های مطرح شده مورد استفاده قرار گیرد.

نتایج به‌دست آمده نشان می‌دهد که پالایش الگوهای آموزشی شبکه عصبی پیش‌بینی کننده بار، به هر یک از روش‌های مذکور، خطای پیش‌بینی را به نحو مناسبی کاهش می‌دهد و می‌تواند سبب صرفه‌جویی قابل توجهی در هزینه‌های بهره‌برداری از سیستم قدرت شود. روش پالایش خیره با آنکه در کاهش خطا مؤثرتر است، به‌علت غیرسیستماتیک و وقتگیر بودن توصیه نمی‌شود. روش پالایش مقایسه‌ای نیز تا حدودی نیاز به تجربه فرد خیره دارد و وقتگیر است. به‌طور ویژه، الگوریتم پیشنهادی PCA که بر مبنای تحلیل مؤلفه اصلی طراحی شده است، با وجود آنکه تأثیر آن در کاهش خطای پیش‌بینی بار نسبت به روش پالایش خیره اندکی کمتر است، ولی به‌علت سادگی به‌کارگیری و سرعت اجرای بالا، برای استفاده‌های عملی و پیش‌بینی کوتاه مدت بار در سیستم‌های قدرت بزرگ واقعی مناسب است.

در شبیه‌سازیهای انجام شده، این روش از لحاظ زمان لازم برای اجرا به مراتب سریعتر از روش مقایسه‌ای عمل می‌کند. مهمترین مزیت این روش نسبت به روش پالایش مقایسه‌ای، تعداد بسیار کم پارامترهای آن یعنی تنها یک محدوده مجاز است که تنظیم آن نیز بسیار ساده‌تر از تنظیم پارامترها در روش مقایسه‌ای است و نیازی به تجربه خیره ندارد.

- | | | |
|---------------------------------|-------------------------------------------------|------------------------------------|
| 1. cross-correlation | ع شرکت‌های مزبور ملزم به پیش‌بینی بار مصرفی خود | 9. over fitting |
| 2. discrete Karhunen Loeve | | 10. early stopping |
| 3. correlation matrix | و ارائه درخواست بار به برق منطقه‌ای می‌باشند. | 11. mean absolute percentage error |
| 4. principal component ratio | 7. conjugate gradient | 12. karhunen loeve |
| 5. principle component analysis | 8. Polak – Ribie`ri | |

مراجع

- Bunn, D. W. and Farmer, E. D. "Review of Short-Term Forecasting Methods in the Electric Power Industry," *Comparative Models for Electrical Load Forecasting*, Wiley, pp. 13-30, 1985.
- Hobbs, B. F. Jitprapaikularn, S. Konda, S. Chankong, V. Loparo, K. A. and Maratukulam, D. J. "Analysis of the Value for Unit Commitment of Improved Load Forecasting," *IEEE Trans. Power Systems*, Vol. 14, No. 4, pp. 1342-1348, 1999.
- Hippert, H. S. Pedreira, C. E. and Souza, R. C. "Neural Networks for Short-Term Load Forecasting: A Review and Evaluation," *IEEE Trans. Power Systems*, Vol. 16, No. 1, pp 44-55, 2001
- Khotanzad, A. Zhou, E. and Elragal, H. "A Neuro-Fuzzy Approach to Short-Term Load Forecasting in a Price-Sensitive Environment," *IEEE Trans. Power Systems*, Vol. 14, No. 4, pp 1273-1282, 2002
- Senjyu, T. Mandal, P. Uezato, K. and Funabashi, T. "Next Day Load Curve Forecasting Using Hybrid Correction Method," *IEEE Trans. Power Systems*, Vol. 20, No. 1, pp. 102-109, Feb. 2005.
- Ling, S. Leung, F. Lam, H. and Tam, P. "A Novel Genetic-Algorithm-Based Neural Network for Short-Term Load Forecasting," *IEEE Trans. Industrial Electronics*, Vol. 50, No. 4, pp. 793-799, Aug. 2003.
- Liao, G. C. and Tsao, T. P. "Application of a Fuzzy Neural Network Combined with a Chaos Genetic Algorithm and Simulated Annealing to Short-Term Load Forecasting," *IEEE Trans. Evolutionary Computation*, Vol. 10, No. 3, pp 330-340, Jun. 2006
- Wenjin, D. and Ping, W. "Application of Pattern Recognition and Artificial Neural Network to Load Forecasting in Electric Power System," *Third Int. Conf. Natural Computation (ICNC 2007)*, Vol. 1, pp. 381-385, Aug. 2007.
- Khotanzad, A. Afkhami-Rohani R. and Maratukulam, D. "ANNSTLF-Artificial Neural Network Short-Term Load Forecaster-Generation Three," *IEEE Trans. Power Systems*, Vol. 13, No. 4, pp. 1413-1422, 1998.
- Kandil, N. Wamkeue, R. Saad, M. and Georges, S. "An Efficient Approach for Short-term Load Forecasting using Artificial Neural Networks," *IEEE Int. Symposium on Industrial Electronics*, Vol. 3, pp. 1928-1932, Jul. 2006.
- Senjyu, T. Mandal, P. and Funabashi, T. "Neural networks approach to forecast several hour ahead electricity prices and load in deregulated market," *Energy Conversion and Management*, Vol. 47, pp 2128-2142, 2006.
- Hagan, M. T. , Demuth, H. B. and Beale, M. *Neural Network Toolbox for Use with Matlab*, Version 5, The MathWorks, 2006.
- Charles, W. T. , *Discrete Random Signals and Statistical Processing*, Prentice Hall, Inc. Englewood cliffs, New Jersey, 1992.
- I. Moghran, and Rahman, S. "Analysis and Evaluation of Five Short Term Load forecasting Techniques," *IEEE Trans. on Power Systems*, Vol. 4, No. 4, pp. 1484-1494, 1989.
- Yu-Jun He; You-Chan Zhu; Dong-Xing Duan, and Wei Sun, "Application of Neural Network Model Based on Combination of Fuzzy Classification and Input Selection in Short Term Load Forecasting," *Proceedings of the Fifth International Conference on Machine Learning and Cybernetics, Dalian*, 13-16 August 2006.