

بهبود برآورد و عملکرد در پخش بار بهینه با استفاده از شبکه عصبی بیزین

مهدی صبری^۱، روشنک رضایی پور^{۲*}

^۱ کارشناسی ارشد گروه مهندسی برق، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

stu.mahdi.sabri@iaut.ac.ir

^۲ استادیار گروه مهندسی برق، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

rezaeipour@iaut.ac.ir

چکیده: طراحی و توسعه آینده سیستم با توجه به رشد بار ولزوم اضافه کردن ژنراتورها، ترانسفورماتورها و خطوط جدید در سیستم قدرت، بدون مطالعه پخش بار امکان پذیر نیست. ضرورت مطالعات پخش بار بهینه نیز علاوه بر موارد ذکر شده برای پخش بار جهت رسیدن به توابع هدف است که در این مقاله، هزینه سوخت ژنراتورها، تلفات توان اکتیو شبکه و شاخص بارپذیری شبکه مورد استفاده قرار گرفته است. بنابراین با استفاده از شبکه عصبی مصنوعی و مقایسه دو الگوریتم پسانتشار خطا از این نوع شبکه و تعریف مدل، به بررسی و تحلیل پخش بار بهینه پرداخته شده است. با استفاده از نمایه های ارزیابی مدل و آزمون مرگان-گرنجر-نیوبلد (*MGN*) عملکرد این دو الگوریتم مورد تحلیل و مقایسه قرار گرفته اند. از روش آماری بوت استرپینگ نیز برای رسیدن به بهترین عملکرد برای بهبود برآورد پخش بار بهینه استفاده شده است. به منظور کاهش گامها با خطای کمتر از ۱٪ برای بهبود برآورد پخش بار بهینه با بهینه سازی توابع تک هدفه مذکور، شبکه های عصبی بیزین و پرسپترون در شبکه استاندارد ۳۰ شین *IEEE* مورد بررسی قرار گرفته اند. نتایج، نقش مؤثر شبکه عصبی بیزین بوت استرپ شده را از لحاظ عملکرد در نرم افزار متلب نشان می دهد.

واژه های کلیدی: برآورد (تخمین)، پخش بار بهینه، شبکه عصبی بیزین، بوت استرپینگ، آزمون *MGN*

* نویسنده مسئول

۱. مقدمه

روش بیزین^۱ نخستین بار در اوایل دهه ۹۰ به وسیله مک کی و نیل در سال ۱۹۹۲ برای شبکه‌های عصبی به کار برده شد [۱ و ۲]. در شبکه‌های بیزی برخلاف شبکه‌های عصبی متداول، هدف یافتن یک بردار وزن بهینه نیست بلکه ارائه عدم قطعیت صریح با توجه به مقادیر وزن به وسیله توزیع احتمال ثانویه است [۳]. توسعه شبکه‌های عصبی به دلیل محدودیت‌های حاکم بر آن‌ها، همواره با مشکلاتی همراه بوده است. از جمله مهم‌ترین این چالش‌ها تعیین سطح بهینه پیچیدگی مورد نیاز برای مدل‌سازی مسئله مورد مطالعه است. بهینه تعداد درجه آزادی در مدل وابسته به تعداد نمونه‌های آموزش داده‌شده، مقدار داده‌های ناخواسته در نمونه‌ها و پیچیدگی توابع اساسی مورد استفاده است. در روش شبکه عصبی، استاندارد روش تعیین پیچیدگی مدل صحیح و تنظیم شبکه با پیچیدگی دلخواه نسبتاً ناپخته است و اغلب با سعی و خطا انجام می‌شود. به عبارتی در این شبکه‌های عصبی، هیچ روش سیستماتیکی برای تعیین مدل مناسب وجود ندارد. در روش شبکه‌های عصبی بیزین این مسئله را می‌توان از راهی سازگار و طبیعی حل کرد. نامعلومی درجه پیچیدگی به وسیله تعریف ابهام اولیه برای مجموعه پارامترهای تعریف شده که تعیین‌کننده درجه پیچیدگی مدل هستند انجام می‌شود. در واقع مدل حاصل، متوسط تمام مدل‌هایی است که پیچیدگی آن‌ها به وسیله احتمال ثانویه حاصل از نمونه‌های ورودی وزن داده شده است. این روش اجازه می‌دهد پیچیدگی‌های متفاوتی در قسمت‌های مختلف مدل به وسیله دسته‌بندی پارامترهای قابل تبادل (که نقش همانندی در مدل دارند) تا هاپیرپارامترها داشته باشیم. حال اگر پیچیدگی‌ها احتمال یکسانی داشته باشند می‌توان برای واریانس هاپیرپارامترهای بین گروهی یک هاپیرپارامتر اولیه، سلسله‌مراتبی تعریف کرد [۴].

در آمار، بوت استرپ^۲ یک متد کامپیوتری برای نسبت دادن معیار دقت به تخمین‌هاست. در این تکنیک، تنها با یک روش خیلی ساده می‌توان تقریباً هر آماره‌ای از توزیع داده‌ها را تخمین زد. به‌طور عمومی این روش از روش‌های باز نمونه‌گیری به حساب می‌آید. به عبارت بهتر، روش بوت استرپینگ تخمین ویژگی‌های یک تخمین‌زننده (مثل واریانس) با استفاده از اندازه‌گیری همین ویژگی‌ها در یک توزیع تقریبی از کل داده‌هاست. در حالتی که بتوان فرض کرد مجموعه‌ای از مشاهده‌ها از جمعیتی مستقل و به‌طور مساوی توزیع شده هستند، بوت استرپینگ می‌تواند با ساخت تعدای بازنمونه پیاده‌سازی شود؛ که

هرکدام از این بازنمونه‌ها، در واقع نمونه‌هایی تصادفی با جایگذاری از مجموعه داده‌های اصلی هستند. همچنین از بوت استرپ می‌توان در ساخت آزمون فرض آماری استفاده کرد. ظاهر ساده این روش ممکن است پیش‌فرض‌های مهم برای آنالیز بوت استرپ (مثل فرض مستقل بودن نمونه‌ها) را پنهان کند درحالی‌که در روش‌های دیگر این پیش‌فرض‌ها به‌صورت رسم بیان می‌شوند [۵].

برای غلبه بر محدودیت‌های انتقال انرژی و استفاده بهینه از ساختار شبکه، راه‌حلی ارائه شده است که از مهم‌ترین آن‌ها می‌توان به اجرای پخش بار بهینه (OPF)^۳ اشاره کرد. در مطالعه پخش بار، قدرت تولیدی شین‌های کنترل‌شده را مقدار مشخصی فرض می‌کنند. تعیین این مقدار از قدرت‌ها به‌طوری که هزینه کل انرژی در سیستم حداقل باشد، بحث عمده‌ای با عنوان توزیع اقتصادی^۴ بار بین ژنراتورها را مطرح می‌کند [۶]. پخش بار بهینه (OPF) به‌طور گسترده‌ای در برنامه‌ریزی و بهره‌برداری سیستم‌های قدرت نقش دارد و هدف آن یافتن مطلوب‌ترین حالت بهره‌برداری از سیستم قدرت است که در آن، ضمن رعایت مجموعه‌ای از محدودیت‌ها، توابع هدف از جمله هزینه‌های تولید، تلفات و بارپذیری بهینه شوند. با توجه به اینکه هدف از پخش بار بهینه، حداقل یا حداکثر کردن یک تابع هدف است، انتخاب این تابع هدف از اهمیت زیادی برخوردار است. انتخاب تابع هدف بیشتر از هر چیزی به دیدگاه بهره‌بردار از سیستم قدرت وابسته است. در این مقاله فقط از سه تابع هدف سوخت ژنراتورها، تلفات توان اکتیو شبکه و بارپذیری شبکه استفاده می‌شود، ولی توابع هدف دیگری قابل تعریف و بررسی هستند.

در مرجع [۱۸] با استفاده از نمایه‌های ارزیابی مدل به بهبود برآورد پخش بار پرداخته شده است و مقایسه‌ها نیز بر اساس داده‌های جداول صورت گرفته‌اند. در مرجع [۱۹] با استفاده از شبکه عصبی و مدل‌سازی محاسباتی اقدام به تخمین نموده است. در مرجع [۲۰] با مدل‌سازی ولتاژ و با استفاده از شبکه عصبی به آنالیز پایداری ولتاژ پرداخته شده است. در این مقاله، با ارائه مدل و بهره‌مندی از روش آماری بوت استرپ به بهبود برآورد پخش بار بهینه پرداخته شده است تا علاوه بر دستیابی به هدف مذکور با کاربرد بوت استرپینگ^۵ در شبکه عصبی بیزین، بتوان نحوه عملکرد و نوآوری به‌کاررفته را با استفاده از تحلیل آماری اثبات کرد. روش‌های متنوعی برای بررسی تفاوت آماری قدرت تخمین مدل‌های مختلف وجود دارد، که از جمله آن می‌توان به آزمون مرگان-گرنجر-نیوبلد^۶ (MGN) اشاره کرد. این

3. Optimal Power Flow
4. Economic Dispatch
5. Bootstrapping
6. Morgan Granger Newbold

1. Bayesian Method
2. Bootstrap

۳. شبکه عصبی بیزین

مک کی در سال ۱۹۹۲ دو سطح از استنتاج‌های بیزی را که می‌توان در مدل‌سازی شبکه عصبی به کار رود تشریح کرده است [۱]. اولین سطح شامل استخراج شبکه وزن‌هاست؛ البته با این فرض که ساختار شبکه انتخاب شده صحیح است. سطح دوم شامل مقایسه مدل‌ها و انتخاب مدل است. از جمله مزایای شبکه بیزی می‌توان به موارد زیر اشاره کرد [۳]:

۱. عدم قطعیت در پارامترهای مدل و پیش‌بینی‌ها به‌طور صریح قابل محاسبه است.

۲. این روش مشکل بیش‌برازشی را حل می‌کند. بنابراین بدون نگرانی از بیش‌آموزشی می‌توان یک شبکه پیچیده را به کار برد.

۳. اهمیت نسبی ورودی‌های مختلف را می‌توان با توجه به روش ARD^4 تعیین کرد [۹].

در روش ARD هر ورودی با یک هایپارامتر همراه است که بزرگی هر وزن را در ارتباط با ورودی متناظر آن کنترل می‌کند. ارزیابی این هایپارامترها مستقل از توزیع اولیه و با استفاده از انحراف استاندارد به‌دست‌آمده از آن‌ها انجام می‌شود. اگر یک هایپارامتر همراه با یک ورودی خاص انحراف استاندارد کوچکی برای وزن مربوط به ورودی خود داشته باشد، این وزن نیز احتمالاً کوچک خواهد بود بنابراین این ورودی اثر ناچیزی بر خروجی خواهد داشت و قابل حذف است. اگر هایپارامتر یک انحراف استاندارد بزرگ را نشان دهد احتمالاً اثر ورودی بزرگ خواهد بود. بنابراین توزیع ثانویه این هایپارامترها منعکس خواهد کرد که کدام یک از وضعیت‌ها در طی آموزش محتمل‌تر هستند.

۴. می‌توان شبکه‌های عصبی با پیچیدگی‌های متفاوت از لحاظ اهداف و اصول را با استفاده از آموزش داده‌ها با هم مقایسه کرد.

۵. با استفاده از «شاهد»^۵ می‌توان بهینه سطح پیچیدگی را برای مدل‌سازی داده‌ها تعیین کرد.

هدف از آموزش در شبکه‌های عصبی متداول یافتن یک بردار وزن است که بهترین برازش مدل با داده‌های y را ایجاد کند. اما در آموزش شبکه بیزین هدف رسیدن به یک توزیع احتمال ثانوی از وزن‌هایی است که بهینه مشاهدات y را ایجاد می‌کنند [۱۰]. این توزیع ثانویه وزن برای ایجاد احتمال پیش‌بینی حاصل از مقادیر ورودی مدل به کار می‌رود.

آزمون برخلاف سایر معیارها، دارای این مزیت است که می‌تواند معنی‌دار بودن تفاوت مدل‌های مختلف را نیز بررسی کند [۷].

در این مقاله ابتدا به بیان تئوری بیزین پرداخته شده، سپس با توضیحات مختصری درباره شبکه عصبی بیزین، روش آماری بوت استرپینگ برای شبکه‌های عصبی مصنوعی تحلیل شده است. شبکه عصبی مصنوعی بوت استرپ شده را با روابط حاکم معرفی کرده، توابع هدف به کار برده شده در پخش بار بهینه را با در نظر گرفتن قیود بیان کرده تا با استفاده از آزمون MGN به تحلیل آماری سه مدل در پخش بار بهینه سیستم مورد مطالعه شبکه‌های عصبی پرسپترون بوت استرپ شده و بیزین بوت استرپ شده پرداخته شود.

۲. تئوری بیزین

با فرض اینکه y یک سری از داده‌های مشاهده شده است که توزیع احتمال آن وابسته به مقادیر سری پارامترهای θ است، تئوری بیزین را می‌توان برای پی بردن به توزیع مشروط θ نامعلوم به کار برد تا داده‌های y مشاهده شده طبق رابطه (۱) مشخص گردد.

$$P(\theta | y, H) = \frac{P(y | \theta, H) P(\theta | H)}{P(y | H)} \quad (1)$$

در این عبارت فرض شده وضعیت مدل H یک حالت نامعلوم است که بر روی احتمال θ ، پایه‌گذاری شده است. توزیع $P(\theta | y, H)$ که توزیع ثانویه^۱ از θ نامیده می‌شود، داده‌های y یا به عبارت ساده‌تر داده‌های ثانویه را فراهم می‌کند. این توزیع نشان می‌دهد درباره پارامترهایی که اطلاعاتی درباره داده‌ها به ما می‌دهند چه می‌دانیم. از طرف دیگر $P(\theta)$ توضیح می‌دهد بدون اطلاع از داده‌ها، در مورد θ چه اطلاعاتی داریم؛ که البته این آگاهی، از توزیع اولیه پارامتر θ به دست می‌آید. توزیع $P(y | \theta, H)$ که به‌عنوان حداکثر احتمال θ^2 شناخته می‌شود درباره θ به ما اطلاعاتی می‌دهد. از این اطلاعات برای تبدیل احتمال اولیه^۳ به ثانویه استفاده می‌شود [۸]. $P(y | H)$ ثابت نرمال‌کننده بوده که به‌عنوان شاهد یا حداکثر احتمال مرزی شناخته می‌شود و از رابطه (۲) به دست می‌آید:

$$P(y | H) = \int P(y | \theta, H) P(\theta | H) d\theta \quad (2)$$

استدلال بیزی بر اساس آگاهی از سابقه و شروطی استوار است. بدون اعمال این فرض‌ها حل تئوری بیزین غیرممکن است [۸]. با این مسئله در شبکه‌های متداول هم مواجهیم. با این تفاوت که در شبکه‌های بیزین فرض‌های به‌کار گرفته شده به‌طور صریح مشخص می‌شوند [۳].

4. Automatic Relevance Determination
5. Evidence

1. Posterior Distribution
2. Maximum Likelihood
3. Prior Probability

۴. بوت استرپینگ

بوت استرپینگ، تخمین با استفاده از اندازه‌گیری ویژگی‌های یک تخمین‌زننده (مثل واریانس) در یک توزیع تقریبی از کل داده‌هاست. بوت استرپینگ می‌تواند با ساخت تعدادی بازنمونه پیاده‌سازی شود، با فرض اینکه مجموعه‌ای از مشاهده‌ها از جمعیتی مستقل و به‌طور مساوی توزیع شده هستند؛ هرکدام از این بازنمونه‌ها، در واقع نمونه‌هایی تصادفی با جایگذاری از مجموعه داده‌های اصلی هستند. همچنین از بوت استرپینگ می‌توان در ساخت آزمون فرض آماری استفاده کرد. از این روش معمولاً به‌عنوان جایگزینی برای روش‌های استنباطی بر پایه فرض‌های پارامتری هنگامی که درباره این فرض‌ها شک داشته باشیم، استفاده می‌شود. یا مواردی که استنباط پارامتری غیرممکن باشد یا برای محاسبه خطای استاندارد فرمول محاسباتی پیچیده شود، از بوت استرپینگ استفاده می‌کنیم. یک فایده بزرگ بوت استرپینگ سادگی آن است. این روش برای تخمین خطای استاندارد و بازه اطمینان برای تخمین‌زننده‌های پیچیده پارامترهای توزیع مثل نقطه‌های صدکی^۱، نسبت‌ها، کسر برتری و ضرایب همبستگی، سرراست است. به علاوه روش مناسبی برای کنترل و بررسی پایداری نتایج است. به دلیل اینکه بوت استرپینگ تحت برخی شرایط به‌طور مجانبی ثابت است، تضمین نمونه متناهی عمومی را فراهم نمی‌کند. ظاهر ساده این روش ممکن است پیش‌فرض‌های مهم برای آنالیز بوت استرپ (مثل فرض مستقل بودن نمونه‌ها) را پنهان کند درحالی‌که در روش‌های دیگر این پیش‌فرض‌ها به‌صورت رسم بیان می‌شوند [۵]. روش بوت استرپ را برای به‌کارگیری در موارد زیر توصیه کرده‌اند:

۱. وقتی که توزیع یک آماره مورد نظر ناشناخته یا پیچیده است.
۲. وقتی که اندازه نمونه برای یک استنباط آماری سرراست ناکافی است.
۳. وقتی که محاسبات توانی لازم است انجام شود، اما نمونه پایلوت کوچکی در اختیار داریم.

۱.۴. شبکه عصبی مصنوعی بوت استرپ شده

یک مدل تخمین احتمالاتی مناسب باید بتواند توزیعی از پیش‌بینی ارائه دهد که هم دقیق و هم قطعی باشد. توزیع پی‌بینی هنگامی دقیق است که مقدار مورد انتظار پیش‌بینی به مقدار واقعی نزدیک باشد. قطعیت یک توزیع پی‌بینی به وسیله گستره آن اندازه‌گیری می‌شود. شبکه‌های عصبی مصنوعی (ANNs) ابزار قابل قبول در توسعه توابع انتقالی هستند، لیکن قادر به تخمین عدم قطعیت پارامترهای خروجی

نیستند. برای اطمینان از داده‌های ایجاد شده توسط توابع انتقالی، لازم است عدم قطعیت پیش‌بینی‌ها کمی شود. بنابراین نیاز است که منابع مختلف عدم قطعیت که بر وزن \hat{w} تأثیر دارد، محاسبه شود [۱۱]. برای رسیدن به این هدف و رفع نگرانی درباره تخمین خروجی $f(x_n; \hat{w})$ از روی $\mu_y(x)$ ، باید این نکته در نظر گرفته شود که سری داده‌های $T = \{(x_n, y_n), n=1, 2, \dots, n_p\}$ که در آموزش شبکه استفاده می‌شوند، یکی از بی‌نهایت داده‌های محتمل است که از داخل داده‌های موجود در ورودی (v_x) و با توجه به توزیع خطای آماری مشتق شده‌اند. در حقیقت تنوع در آموزش سری داده‌ها به دلیل تعدد در نمونه‌گیری توأمان از ورودی‌ها (x_n) و خروجی‌های متناظر این ورودی‌هاست. آموزش با هر سری از داده‌های T به سری متفاوتی از وزن‌های شبکه منجر می‌شود. بنابراین یک توزیعی از تابع خطا خواهیم داشت که واریانس آن از رابطه (۳) به‌صورت زیر به دست می‌آید (با توجه به سری داده‌های T):

$$\sigma_f^2(x) = E \left\{ \left[f(x_n; \hat{w}) - \left[f(x_n; \hat{w}) \right] \right]^2 \right\} \quad (3)$$

از آنجایی که در عمل ساختار شبکه عصبی یک الگوریتم کامل نیست و به‌طور سیستماتیک کم یا بیش‌برآوردی نتیجه، محتمل است یعنی مقادیر مورد انتظار $E[f(x_n; \hat{w})]$ برابر با عملکرد قطعی واقعی $\mu_y(x)$ نیست، که این اختلاف بایاس نامیده می‌شود. البته بایاس در شبکه‌های عصبی کامل برابر صفر است. واریانس با توجه به تمام مجموعه داده‌های محتمل آموزش خطا $f(x; \hat{w}) - \mu_y(x)$ برابر است با:

$$E \left\{ (f(x; \hat{w}) - \mu_y(x))^2 \right\} = E \left\{ \left[f(x; \hat{w}) - E[f(x; \hat{w})] \right]^2 \right\} + \left\{ E[f(x; \hat{w})] - \mu_y(x) \right\}^2 \quad (4)$$

نخستین عبارت بعد مساوی واریانس، تابع توزیع $f(x; \hat{w})$ اصطلاح دوم مربع بایاس است. اگر $E \left\{ \left[f(x; \hat{w}) - E[f(x; \hat{w})] \right]^2 \right\}$ برابر صفر شود، تولید مضاعف نخواهیم داشت. منبع دیگر خطا در تخمین $\mu_y(x)$ از انتخاب نامناسب ساختار شبکه ناشی می‌شود. به علاوه در شبکه‌های با تعداد گره‌های خیلی کم از آنجایی که تابع توزیع $f(x; \hat{w})$ انعطاف ناکافی برای مدل کردن داده‌ها دارد، بایاس زیاد می‌شود. از طرف دیگر، انعطاف‌پذیری مدل با افزایش تعداد گره‌ها (تعداد پارامترهای ورودی) به‌طور فزاینده‌ای افزایش می‌یابد. افزایش واریانس (عبارت اول در رابطه ۴) سبب افزایش بایاس و در نتیجه بیش‌آموزشی در شبکه خواهد شد. منابع دیگر عدم قطعیت در اجرای شبکه از این امر ناشی می‌شود که در محلی که تابع خطا حداقل

بهبود برآورد و عملکرد در پخش بار بهینه با استفاده از شبکه عصبی بیزین ۵

استفاده می‌شود. برای محاسبه خطای تعمیم از متوسط نتایج حاصل از اجرای مدل برای نمونه‌های بوت استرپ شده، استفاده می‌شود. در نهایت خطای تعمیم E_0 برای شبکه عصبی از رابطه (۵) به دست آمده است [۱۱]:

$$E_0 = \frac{\sum_{b=1}^B \sum_{i \in A_b} (y_i - f_{ANN}(x_i; w_i / T^B))^2}{\sum_{b=1}^B \neq (A_b)} \quad (5)$$

خروجی‌های حاصل از نمونه‌های بوت استرپ با علامت $f_{ANN}(x_i; w_i / T^B)$ نشان داده می‌شود. A_b سری از شاخص‌هایی برای جفت‌های مشاهده‌ای که شامل نمونه‌های بوت استرپ T^B نیستند، w_i و x_i به ترتیب نشانگر بردار ورودی و وزن، $\neq (A_b)$ تعداد شاخص‌های جفت مشاهده‌ای در A_b برای یک ورودی جدید x تخمین شبکه عصبی بوت استرپ شده $\hat{\theta}(x)$ (که در حقیقت متوسط B تخمین حاصل از بوت استرپ است) از رابطه (۶) به صورت زیر به دست می‌آید:

$$\hat{\theta}(x) = \frac{1}{B} \sum_{b=1}^B f_{ANN}(x_i; w_i / T^B) \quad (6)$$

و برای تخمین $\delta_{boot}^2(x)$ از رابطه (۷) استفاده می‌شود:

$$\delta_{boot}^2(x) = \frac{\sum_{b=1}^B \sum_{i \in A_b} (y_i - f_{ANN}(x_i; w_i / T^B))^2}{B - 1} \quad (7)$$

معنی‌داری فواصل اطمینان در سطح احتمال α نشانگر تکرارپذیری این روش است. مقدار معمول α حدوداً ۰/۰۵ است که با توجه به فرمول $100(1 - \alpha\%)$ برابر حدود اطمینان ۹۵٪ می‌باشد. به منظور تعیین فواصل اطمینان در سطح احتمال مورد نظر رابطه (۸) به کار می‌رود:

$$\hat{\theta}(x) \pm t_{n-p}^{\alpha/2} \delta(x) \quad (8)$$

$\delta(x)$ انحراف استاندارد B تعداد تخمین حاصل از بوت استرپ است. مقدار t از جدول t - استیودنت و $t_{n-p}^{\alpha/2}$ درصد $\alpha/2$ برای توزیع t - استیودنت با درجه آزادی $n-p$ (تعداد کل پارامترها در شبکه عصبی و n تعداد کل مشاهدات) است.

۵. توابع هدف

هدف از OPF در این مقاله، بهینه‌سازی تک‌هدفه هریک از سه تابع هزینه سوخت ژنراتورها، تلفات شبکه و بارپذیری در سیستم قدرت است. در ادامه روابط مربوط به هریک از توابع هدف تشریح شده است.

۱.۵. تابع هزینه سوخت ژنراتور

حداقل نمودن این تابع به معنای تعیین توان‌های تولیدی هر واحد نیروگاهی در شبکه است به گونه‌ای که با توجه به تابع

می‌شود، الگوریتم نیز خود را به حداقل برساند، که در این صورت آموزش ممکن است قبل از موعد مقرر و قبل از رسیدن به حداقل متوقف شود.

کمی کردن دقت تخمین $f(x; \hat{w})$ از یک عملکرد قطعی درست، $\mu_y(x)$ (از نظر فاصله اطمینان) نیاز به فرض یک توزیع برای خطا $(f(x; \hat{w}) - \mu_y(x))^2$ در رابطه (۴) و تخمین واریانس آن است. در عمل معمول است که فرض کنیم بایاس یعنی عبارت دوم در رابطه (۴) با توجه به عبارت اول نادیده گرفته شده است. در حقیقت شبکه عصبی در مجموعه داده‌های آموزشی از طریق بایاس^۱ برآورد را انجام می‌دهد (برای مثال همیشه تمایل به پیک بیش از حد دارند). اگرچه در بسیاری از کاربردهای واریانس اصطلاح غالب در واقع اصطلاح بایاس است [۱۲] و علاوه بر این، اگر محاسبه اجزای بایاس ممکن بود، می‌توانست برای اصلاح اولیه به منظور رسیدن به یک تابع دقیق‌تر به کار رود. به همین دلیل این مقاله روی مسئله تخمین واریانس $\sigma_f^2(x)$ با استفاده از تکنیک بوت استرپ متمرکز شده است. بوت استرپینگ تخمین ویژگی‌های یک تخمین‌زننده (مثل واریانس) با استفاده از اندازه‌گیری همین ویژگی‌ها در یک توزیع تقریبی از کل داده‌هاست. در حالتی که بتوان فرض کرد مجموعه‌ای از مشاهده‌ها از جمعیتی مستقل و به طور مساوی توزیع شده باشند، بوت استرپینگ می‌تواند با ساخت تعدادی بازنمونه پیاده‌سازی شود؛ هرکدام از این بازنمونه‌ها در واقع نمونه‌هایی تصادفی با جایگذاری از مجموعه داده‌های اصلی هستند. آموزش شبکه به طور جداگانه برای هریک از نمونه‌های تولید شده انجام می‌شود.

فرض کنید داده‌ها از یک سری داده‌های تصادفی $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ با اندازه n که از جمعیتی با توزیع احتمالی نامعلوم F گرفته شده است. جایی که $t_i = \{(x_i, y_i)\}$ یک نمونه تصادفی با توزیع مستقل و یکسان از F و شامل بردار پیش‌بینی‌کننده x_i و متغیر خروجی y_i متناظر آن است. \hat{F} تابع توزیع تجربی از T_n و نمونه تصادفی با اندازه n است که از یک توزیع مستقل و یکسان که با جایگذاری از \hat{F} گرفته شده است. درحالی‌که t_i یک مشاهده تصادفی منفرد از $t_i = \{(x_i, y_i)\}$ سری از نمونه‌های بوت استرپ شده به صورت T^1, T^2, \dots, T^B ارائه شده که B تعداد نمونه‌های بوت استرپ شده با دامنه بین ۵۰ تا ۲۰۰ در نظر گرفته شده است [۱۳]. برای هر T^B شبکه عصبی یک بار جداگانه اجرا می‌شود که خروجی آن با $f_{ANN}(x_i; w_i / T^B)$ نشان داده می‌شود. برای ارزیابی آموزش شبکه از لاهایی که در داخل نمونه B نیستند

1. Bias

سوخت آن واحد، حداقل هزینه کل به دست آید. این تابع به صورت رابطه (۹) نشان داده می شود [۱۴].

$$f_1 = \sum_{i=1}^n c_i (P_{Gi}) = \sum_{i=1}^n \alpha_{0i} + \alpha_{1i} P_{Gi} + \alpha_{2i} P_{Gi}^2 \quad (9)$$

که در آن، P_{Gi} توان خروجی ژنراتور شماره i بر حسب MW (مگاوات) بوده و α_{0i} ، α_{1i} و α_{2i} ضرایب ثابت مربوط به تابع هزینه نیروگاه شماره i هستند. اطلاعات مربوط به تابع هزینه نیروگاه‌ها برای شبکه مورد مطالعه در [۲۱] آمده است.

۲.۵. تابع تلفات توان اکتیو شبکه

تابع هدف دیگر مسئله OPF ، حداقل نمودن مجموع تلفات در شبکه است، بدین معنی که تولید واحدهای نیروگاهی و توان عبور داده شده از خطوط به گونه‌ای تنظیم شوند که حداقل تلفات در شبکه با رابطه (۱۰) به دست آید [۱۵].

$$f_2 = f(x, u) = \sum_{i=1}^n \sum_{j=1}^n V_i V_j Y_{ij} \cdot \cos(\alpha_{ij} + \theta_j - \theta_i) \quad (10)$$

که در آن، V_i اندازه ولتاژ شین شماره i اندازه درایه ماتریس ادمیتانس شبکه Y_{bus} ، θ_i زاویه ولتاژ شین شماره i زاویه درایه ij ماتریس ادمیتانس شبکه Y_{bus} می باشد.

۳.۵. شاخص بارپذیری شبکه

بارپذیری شبکه یعنی توانایی شبکه به انتقال توان اکتیو که تحت تأثیر توپولوژی شبکه، پارامترهای خط، ولتاژ و جریان وسایل تنظیم کننده و محدودیت‌های عملی است. هدف از ماکزیم نمودن بارپذیری در شبکه، استفاده از ظرفیت خالی خطوط به منظور افزایش توان انتقال است و با رابطه (۱۱) و به شکل زیر بیان می شود [۱۶].

$$f_3 = \rho(x, u) \quad (11)$$

با توجه به روابط (۱۲) و (۱۳)

$$P_G - \rho P_D = f_p(x, u) \quad (12)$$

$$Q_G - \rho Q_D = f_q(x, u) \quad (13)$$

P_G و Q_G بردارهای توان اکتیو و راکتیو ژنراتورها، P_D و Q_D بردارهای توان اکتیو و راکتیو بار شین‌ها، $f_p(x, u)$ و $f_q(x, u)$ بردارهای معادلات پخش بار توان اکتیو و راکتیو هستند.

۶. قیود

توابع $h(x, u)$ و $g(x, u)$ تساوی و نامساوی‌هایی هستند که باید در فرایند جست‌وجو پاسخ بهینه بیان شوند. قیود مساوی، قیود پخش بار هستند و قیود نامساوی مربوط به محدودیت‌ها روی متغیرهای کنترل و محدودیت‌های عملکردی سیستم قدرت هستند.

۱.۶. قیود مساوی

قیود مساوی معادلات پخش بار مربوط به توان‌های اکتیو و راکتیو هستند که با روابط (۱۴) و (۱۵) به صورت زیر بیان می شوند:

$$P_{Gi} - P_{Di} - f_{Pi}(x, u) = 0 \quad (14)$$

$$Q_{Gi} - Q_{Di} - f_{Qi}(x, u) = 0 \quad (15)$$

که در آن، P_{Gi} و Q_{Gi} توان‌های اکتیو و راکتیو خروجی ژنراتور شماره i و P_{Di} و Q_{Di} توان‌های اکتیو و راکتیو بار در شین شماره i و f_{Pi} و f_{Qi} معادلات پخش بار توان‌های اکتیو و راکتیو در شین شماره i می باشند.

۲.۶. قیود نامساوی

تابع $h(x, u)$ شامل قیود نامساوی سیستم هستند که موارد زیر را در بر می گیرند [۱۴].

الف. حدود مجاز تولید: توان اکتیو و راکتیو خروجی ژنراتورها

توسط حدود بالا و پایین آن با روابط (۱۶) و (۱۷) به صورت زیر محدود می شود.

$$P_{Gi}^{\min} \leq P_{Gi} \leq P_{Gi}^{\max} \quad (16)$$

$$Q_{Gi}^{\min} \leq Q_{Gi} \leq Q_{Gi}^{\max} \quad (17)$$

ب. حدود مجاز انتقال: حدود مجاز عبور توان در خط انتقال طبق

رابطه (۱۸) و به صورت زیر است.

$$|S_{ij}| \leq S_{ij}^{\max} \quad (18)$$

ج. حدود مجاز ولتاژ: محدوده مجاز ولتاژ در هر شین به صورت

زیر و طبق رابطه (۱۹) است.

$$V_i^{\min} \leq V_i \leq V_i^{\max} \quad (19)$$

۷. پیاده‌سازی توابع هدف و قیود

مسئله OPF با استفاده از نرم‌افزار متلب انجام می شود. در روش پیشنهادی، یک معیار توقف برای تعداد بهینه در نظر گرفته شده است. این معیار در دو مرحله انجام می شود: در مرحله اول تابع هدف بدون عنصر بهینه محاسبه می شود. در مرحله دوم، توابع هدف که همان روابط (۹)، (۱۰) و (۱۱) هستند، با نخستین عنصر بهینه محاسبه می شوند. اختلاف مابین دو مرحله، میزان اثرپذیری نامیده می شود. روند بهینه‌سازی تا زمانی ادامه پیدا می کند که اختلاف مابین دو تابع هدف متوالی ضریب اثرپذیری کوچک‌تر از میزان اثرپذیری گردد.

الگوریتم پیشنهادی روی شبکه‌های استاندارد ۳۰ شین $IEEE$

پیاده‌سازی و توسط شبکه‌های عصبی پرسپترون و بیزین مورد بررسی قرار می گیرد. مسئله بهینه‌سازی به روش اولیه-دوگانه نقطه داخلی انتخاب می شود.

۹. سیستم مورد مطالعه

به منظور مطالعه بهبود برآورد پخش بار بهینه با شبکه عصبی بیزین و عملکرد آن روی سیستم‌های تست ۳۰ شین IEEE بهبود برآورد پخش بار بهینه با شبکه عصبی بیزین و شبکه عصبی پرسپترون در این سیستم مورد بررسی و مقایسه قرار گرفته است.

۱.۹. شبکه ۳۰ شین IEEE

شبکه ۳۰ شین IEEE دارای ۳۰ شین، ۴۱ خط و ۶ ژنراتور در شین‌های ۱، ۲، ۵، ۸، ۱۱ و ۱۳ است. در این شبکه، حداکثر توان بار برابر است با ۲۸۳/۴ مگاوات و حداکثر و حداقل تولید به ترتیب برابر ۴۳۵ و ۱۱۷ مگاوات هستند [۱۷]. پخش بار بهینه برای شبکه ۳۰ شین IEEE با در نظر گرفتن سه تابع تک‌هدفه صورت پذیرفته است. این توابع هدف شامل تابع هزینه سوخت ژنراتورها، تابع تلفات توان اکتیو شبکه و شاخص بارپذیری شبکه است.

۲.۹. شبکه عصبی پرسپترون بوت استرپ شده

در این مقاله، شبکه عصبی پرسپترون بوت استرپ شده برای پخش بار بهینه سیستم ۳۰ شین IEEE معرفی شده تا اندازه نمونه برای یک استنباط آماری سراسر کافی باشد و وقتی که محاسبات توانی لازم است انجام شود، نمونه پایلوت بزرگ و قابل قبولی در اختیار داشته باشیم و همچنین قابلیت و سرعت عملکرد الگوریتم‌های پیشنهادی نیز در چنین شرایطی قابل ارائه خواهد بود.

روش بوت استرپ را روی شبکه عصبی پرسپترون اعمال کنید. سه مدل برای پخش بار بهینه انجام شده به روش اولیه دوگانه نقطه داخلی انتخاب شود که به ترتیب شامل هزینه سوخت ژنراتورها، تلفات توان اکتیو شبکه و شاخص بارپذیری شبکه هستند. نمایه‌های ارزیابی مدل یا شاخص‌های آماری نیز شامل ضریب همبستگی (CC)، ریشه میانگین مربعات خطا (RMSE)، ضریب نش ساتکلیف (NS) و بایاس (Bias) هستند. در جدول (۱) نتایج شبکه عصبی پرسپترون بوت استرپ شده برای سه مدل انتخابی پخش بار بهینه انجام شده با شاخص‌های آماری در مراحل آموزش و صحت‌سنجی برای سیستم ۳۰ شین IEEE نشان داده شده است. با توجه به جدول (۱) و با در نظر گرفتن شاخص‌های آماری بایاس و ریشه میانگین مربعات خطا در مراحل آموزش و صحت‌سنجی، می‌توان به این نتیجه رسید که شبکه عصبی پرسپترون بوت استرپ شده برای مدل شاخص بارپذیری شبکه در سیستم ۳۰ شین IEEE بهترین عملکرد را دارد. خروجی تحلیلی شبکه عصبی پرسپترون بوت استرپ شده برای مدل شاخص بارپذیری شبکه مطابق شکل‌های (۱)، (۲) و (۳) بدین صورت است.

هر چند معیارهای مختلفی مثل معیار اطلاعات آکایک^۱، میانگین هندسی نسبت خطا^۲ و انحراف استاندارد هندسی نسبت خطا^۳ وجود دارند که از جمله معیارهای کاربردی و مفید در زمینه بررسی قدرت مدل‌ها برای پیش‌بینی‌های ایجاد شده هستند، هیچ‌یک از آن‌ها قادر نیستند برتری یک روش را به صورت آماری بررسی کنند. روش‌های متنوعی برای بررسی تفاوت آماری قدرت تخمین مدل‌های مختلف وجود دارد؛ از جمله آن می‌توان به آزمون مرگان-گرنجر-نیوبلد (MGN) اشاره کرد. این آزمون برخلاف سایر معیارها، دارای این مزیت است که می‌تواند معنی‌دار بودن تفاوت مدل‌های مختلف را نیز بررسی کند [۷]. برای معنی‌دار شدن تفاوت و تأثیر مدل‌ها بر بهبود خطا در مرحله آموزش و صحت‌سنجی، معیار MGN باید به ترتیب بیشتر از ۱/۹۹ و ۲/۰۱ باشد.

در این آزمون، ابتدا خطای پیش‌بینی دو مدل مختلف که با $e_{1,t}$ و $e_{2,t}$ نشان داده می‌شود محاسبه می‌گردد. سپس مجموع (s_t) و تفاوت (d_t) خطای پیش‌بینی بر اساس روابط زیر محاسبه می‌شود.

$$s_t = e_{1,t} + e_{2,t} \quad (20)$$

$$d_t = e_{1,t} - e_{2,t} \quad (21)$$

$$e_{1,t} = X_m - X_{1p} \quad (22)$$

$$e_{2,t} = X_m - X_{2p} \quad (23)$$

X_{1p} و X_{2p} به ترتیب مقادیر پیش‌بینی شده خروجی توسط مدل‌های اول و دوم (الگوریتم‌های پخش‌کننده خطا به کار برده شده در این مقاله) و X_m مقادیر اندازه‌گیری شده خروجی هستند. آزمون برابری میانگین مجذور خطای دو روش مختلف، در مقابل کمتر بودن خطای روش اول را می‌توان با استفاده از آماره MGN طبق رابطه (۲۴) به صورت زیر بررسی کرد.



$$MGN = \frac{\rho_{sd}}{\sqrt{1 - \rho_{sd}}} \sqrt{N - 1} \quad (24)$$

که در آن ρ_{sd} ضریب همبستگی بین d_t و s_t و N تعداد مشاهدات است. مقدار MGN محاسبه شده با جدول t با درجه آزادی $N-1$ محاسبه می‌شود.

1. Akaike Information Criterion
2. Geometric Mean of Error Ratio
3. Geometric Standard Deviation of Error Ratio


جدول (۱): نتایج شبکه عصبی پرسپترون بوت استرپ شده برای سیستم ۳۰ شین *IEEE* (در پخش بار بهینه)

صحت سنجی				آموزش				مدل‌ها
Bias	NS	RMSE	CC	Bias	NS	RMSE	CC	
$3/34 \times 10^{-2}$	۱	$5/7 \times 10^{-1}$	۱	$3/36 \times 10^{-1}$	۱	$5/8 \times 10^{-1}$	۱	هزینه سوخت ژنراتورها (\$/MW/h)
$1/23 \times 10^{-1}$	۱	$3/5 \times 10^{-1}$	۱	$1/19 \times 10^{-1}$	۱	$3/44 \times 10^{-1}$	۱	تلفات توان اکتیو شبکه (MW)
$7/6 \times 10^{-1}$	۱	$2/76 \times 10^{-1}$	۱	$7/65 \times 10^{-1}$	۱	$2/77 \times 10^{-1}$	۱	شاخص بارپذیری شبکه (MW-VAR)



شکل (۲): نمودار تحلیلی وضعیت آموزش برای مدل شاخص بارپذیری شبکه در پخش بار بهینه شبکه ۳۰ شین *IEEE*

شکل (۱): عملکرد شبکه عصبی پرسپترون بوت استرپ شده برای مدل شاخص بارپذیری شبکه در پخش بار بهینه شبکه ۳۰ شین *IEEE*



شکل (۳): رگرسیون داده‌ها در شبکه عصبی پرسپترون بوت استرپ شده برای مدل شاخص بارپذیری شبکه در پخش بار بهینه شبکه ۳۰ شین *IEEE*



۳.۹. شبکه عصبی بیزین بوت استرپ شده

روش به کار برده شده یکی از روش های سیستم پشتیبان تصمیم گیری است که ابزار قدرتمندی در مدل کردن روابط علی و معلولی در قالب شبکه های از احتمالات است. نکته بسیار مهم درباره روش شبکه عصبی بیزین بوت استرپ شده این است که این روش به اطلاعات دقیق و تاریخیچه کامل یک واقعیت نیاز ندارد بلکه می تواند با استفاده از اطلاعات ناقص و غیردقیق نیز به نتایج بسیار قانع کننده ای در زمینه تخمین وضعیت فعلی یا آینده یک سیستم دست یابد. همچنین یک روش سازگار و انعطاف پذیر برای مدل کردن موقعیت های غیرقطعی و یک مدل گرافیکی مبتنی بر ادراک مستقیم از اندرکنش میان علت و معلول های مختلف ارائه می کند. همچنین یک روش بسیار مفید در مدل کردن موقعیت های نامطمئن و غیرقطعی بر اساس روابط علت و معلولی است. در شبکه های عصبی یکی از روش های دستیابی مؤثر به پارامترهای بهینه، استفاده از تنظیم بیزین است که به طور اتوماتیک مقادیری مناسب برای پارامترهای تابع قرار می دهد.

روش بوت استرپ را روی شبکه عصبی بیزین اعمال کنید. سه مدل و همچنین نمایه های ارزیابی مدل یا شاخص های آماری برای پخش بار بهینه همانند شبکه عصبی پرسپترون بوت استرپ شده را انتخاب کنید. در جدول (۲)، نتایج شبکه عصبی بیزین بوت استرپ شده برای سه مدل انتخابی پخش بار بهینه انجام شده با شاخص های آماری در مراحل آموزش و صحت سنجی برای سیستم ۳۰ شین IEEE نشان داده شده است. انتخاب بهترین عملکرد با توجه یکی از سه مدل پخش بار طبق جدول (۲)، توسط ارزیابی شاخص های آماری انجام می گیرد. با توجه به جدول (۲) و با در نظر گرفتن شاخص های آماری بایاس و ریشه میانگین مربعات خطا در مراحل آموزش و صحت سنجی، می توان به این نتیجه رسید که شبکه عصبی بیزین بوت استرپ شده برای مدل تلفات توان اکتیو شبکه در سیستم ۳۰ شین IEEE بهترین عملکرد را دارد. خروجی تحلیلی شبکه عصبی بیزین بوت استرپ شده برای مدل تلفات توان اکتیو شبکه مطابق شکل های (۴)، (۵) و (۶) بدین صورت است.

جدول (۲): نتایج شبکه عصبی بیزین بوت استرپ شده برای سیستم ۳۰ شین IEEE (در پخش بار بهینه)

صحت سنجی				آموزش				مدل ها
Bias	NS	RMSE	CC	Bias	NS	RMSE	CC	
$1/7 \times 10^{-10}$	۱	$4/2 \times 10^{-10}$	۱	$1/9 \times 10^{-10}$	۱	$4/4 \times 10^{-10}$	۱	هزینه سوخت ژنراتورها (\$/MW/h)
$9/11 \times 10^{-10}$	۱	$9/54 \times 10^{-10}$	۱	$9/58 \times 10^{-10}$	۱	$9/79 \times 10^{-10}$	۱	تلفات توان اکتیو شبکه (MW)
$4/12 \times 10^{-10}$	۱	$6/42 \times 10^{-10}$	۱	$4/1 \times 10^{-10}$	۱	$6/4 \times 10^{-10}$	۱	شاخص بارپذیری شبکه (MW-VAR)




شکل (۵): نمودار تحلیلی وضعیت آموزش برای مدل تلفات توان اکتیو

شبکه در پخش بار بهینه شبکه ۳۰ شین IEEE

(۴) عملکرد شبکه عصبی بیزین بوت استرپ شده برای مدل تلفات توان

اکتیو شبکه در پخش بار بهینه شبکه ۳۰ شین IEEE



شکل (۶): رگرسیون داده‌ها در شبکه عصبی بیزین بوت استرپ شده برای مدل تلفات توان اکتیو شبکه در پخش بار بهینه شبکه ۳۰ شین IEEE


۴.۹. تحلیل آماری

شبکه هستند، آورده شده است. درباره مدل‌های مورد بررسی در جدول مذکور می‌توان چنین گفت که مدل هزینه سوخت ژنراتورها در مقایسه با دو مدل دیگر در داده‌های مربوط به آموزش و صحت‌سنجی تفاوت معنی‌داری داشته و در بهبود خطا مؤثرتر است. شکل (۷) مربوط به هیستوگرام خطای تحلیل شبکه عصبی پرسپترون بوت استرپ شده و شکل (۸) مربوط به هیستوگرام خطای تحلیل و برآورد شبکه عصبی بیزین بوت استرپ شده است که خطای مناسب‌تری را با توجه به خط خطای صفر مشاهده شد.


با استفاده از آزمون *MGN* به تحلیل آماری سه مدل در پخش بار بهینه سیستم ۳۰ شین IEEE برای شبکه عصبی بیزین بوت استرپ شده و پرسپترون بوت استرپ شده پرداخته شده است. برای معنی‌دار شدن تفاوت و تأثیر مدل‌های انتخاب شده بر بهبود خطا در مرحله آموزش و صحت‌سنجی، معیار *MGN* باید به ترتیب بیشتر از ۱/۹۹ و ۲/۰۱ باشد. در جدول (۳) نتایج مربوط به آزمون *MGN* در شبکه‌های عصبی بیزین بوت استرپ شده و پرسپترون بوت استرپ شده برای سه مدل که شامل هزینه سوخت ژنراتورها، تلفات توان اکتیو شبکه شاخص بارپذیری

جدول (۳): نتایج آزمون *MGN* برای مدل‌ها در سیستم ۳۰ شین IEEE (در پخش بار بهینه)

مدل‌ها		شاخص بارپذیری شبکه		تلفات توان اکتیو شبکه		هزینه سوخت ژنراتورها	
صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش
۲/۱۳	۲/۱۹	۲/۰۸	۲/۰۴	۲/۳۰	۲/۲۱		
MGN							

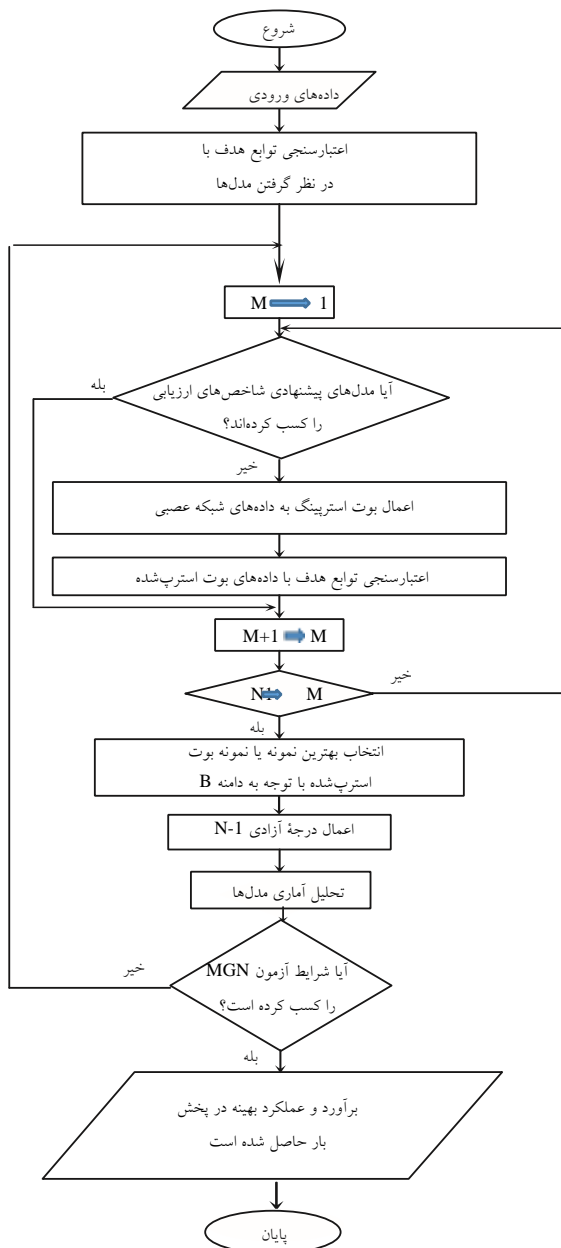


شکل (۸): هیستوگرام خطای تحلیل و برآورد شبکه عصبی بیزین بوت استرپ شده



شکل (۷): هیستوگرام خطای تحلیل شبکه عصبی پرسپترون بوت استرپ شده

۱۰. روند نمای پیشنهادی



شکل (۹): روند نمای پژوهشی

۱۱. نتیجه‌گیری

در این مقاله به مطالعه شبکه‌های عصبی بیزین بوت استرپ شده و پرسپترون بوت استرپ شده روی پخش بار بهینه سیستم ۳۰ شین IEEE پرداخته شده است. هر پارامتر خروجی پخش بار بهینه با توجه به تابع هدف، به عنوان یک مدل لحاظ شده و هریک از این مدل‌ها توسط نمایه‌های ارزیابی مدل مورد ارزیابی قرار گرفته‌اند. روش آماری بوت استرپینگ برای نسبت دادن معیار دقیق به تخمین‌ها و همچنین بررسی پایداری نتایج و رسیدن به استنباط آماری سراسر با توجه به اندازه نمونه مطالعه شده استفاده شده و برای مقایسه نتایج و همچنین برای

در مرجع [۱۸] از نمایه‌های ارزیابی مدل کمتری استفاده شده و برای مقایسه نیز از هیچ آزمون یا تحلیل آماری بهره نبرده است. به توضیح مشخص است روش بهینه‌سازی و همچنین تحلیل آماری نتایج به دست آمده در این مقاله، به صورت ملموس‌تر و با دقتی بیشتر ارائه شده است. در مرجع [۱۹] با استفاده از شبکه عصبی و مدل‌سازی محاسباتی اقدام به تخمین نموده است در حالی که در این مقاله مدل‌سازی بر اساس پارامترهای کاربردی شبکه صورت گرفته و با استفاده از روش بوت استرپینگ به بهبود عملکرد روش پیشنهادی در برآورد با استفاده از تحلیل آماری پرداخته شده است. در مرجع [۲۰] با مدل‌سازی ولتاژ و با استفاده از شبکه عصبی به آنالیز پایداری ولتاژ پرداخته شده است که با روش پیشنهادی در این مقاله از لحاظ تنوع مدل‌های انتخابی، تحلیل آماری و بهبود برآورد تفاوت‌هایی دارد. با در نظر گرفتن مقادیر جدول (۳) معنی‌دار بودن تفاوت و تأثیر مدل‌های انتخاب شده بر بهبود خطا در مرحله آموزش و صحت‌سنجی در شبکه‌های عصبی بیزین بوت استرپ شده و پرسپترون بوت استرپ شده ارائه می‌شود. با توجه به جدول (۳) و نمایه‌های ارزیابی مدل‌ها در شبکه‌های عصبی بیزین و پرسپترون بوت استرپ شده مطابق جداول (۱) و (۲)، ضریب همبستگی (CC) و ضریب نش سائکلیف (NS) به دلیل مقادیر بسیار نزدیک به عدد یک، با مقدار یک در نظر گرفته شده‌اند و با توجه به مقادیر ریشه میانگین مربعات خطا (RMSE) و بایاس (Bias) می‌توان به این نتیجه رسید که شبکه عصبی بیزین بوت استرپ شده، بهترین عملکرد را در مدل هزینه سوخت ژنراتورها نسبت به شبکه پرسپترون بوت استرپ شده دارد. صحت این ادعا با استفاده از تحلیل آماری مورد ارزیابی قرار گرفته است. شبکه پرسپترون بوت استرپ شده نیز دارای عملکردی قابل قبول در مدل‌های تلفات توان اکتیو شبکه و شاخص بارپذیری نسبت به شبکه عصبی بیزین بوت استرپ شده است. این عملکرد با توجه به روش پیشنهاد شده از دقت بسیار زیادی با توجه شاخص‌های ارزیابی برخوردار است.

بنابراین با توجه به عملکرد و کاهش خطا در گام‌های مربوط به آموزش، اعتبارسنجی، صحت‌سنجی و تمامی داده‌ها در شبکه عصبی بیزین بوت استرپ شده از دید مدل هزینه سوخت ژنراتورها، بهبود برآورد و عملکرد پخش بار بهینه را برای سیستم ۳۰ شین IEEE ارائه داده است.

$$CC = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}}, -1 \leq R \leq 1 \quad (25)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (26)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2}, -\infty \leq NS \leq 1 \quad (27)$$

$$Bias = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \quad (28)$$

در روابط بالا x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام‌های زمانی، \bar{x} و \bar{y} نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی است. از معیارهای فوق برای مقایسه و تحلیل بیشتر نتایج استفاده شده است.

معنی دار کردن نتایج نمایه‌های ارزیابی مدل، از آزمون مرگان-گرنجر-نیولد (MGN) استفاده شده است. با اعمال این روش‌ها، علاوه بر کاهش گام‌های مربوط به آموزش، اعتبارسنجی، صحت‌سنجی و تمامی داده‌ها این نتیجه حاصل شد که با ارائه مدل‌های پیشنهادی، بهبود برآورد و عملکرد پخش بار بهینه در سیستم مورد مطالعه با شبکه عصبی بیزین بوت استرپ شده به شکل مطلوب‌تری امکان‌پذیر است.

۱۲. ضمیمه‌ها

۱.۱۲. ارزیابی مدل

در این مقاله به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب همبستگی (CC)، ریشه میانگین مربعات خطا (RMSE)، ضریب نش ساتکلیف (NS) و بایاس (Bias) طبق روابط زیر استفاده شد. بهترین مقدار برای این چهار معیار به ترتیب یک، صفر، یک و صفر است.

مراجع

- [1] MacKay, D. J. C., "Bayesian Interpolation. Neural Computation", Vol. 4, pp. 415-447, 1992.
- [2] Neal, R. M., "Bayesian Training of Backpropagation Networks by The Hybrid Monte Carlo Method", Citeseer 1992.
- [3] Govindaraju, R. S. and Rao, A. R., "Artificial Neural Networks in Hydrology", Vol. 36: Springer Science & Business Media, 2013.
- [4] Guha, N., Wu, X., Efendiev, Y., Jin, B., and Mallick, B. K., "A Variational Bayesian Approach for Inverse Problems with Skew-t Error Distributions", Journal of Computational Physics, Vol. 301, pp. 377-393, 2015.
- [5] Shin, D. W. and Hwang, E., "Stationary Bootstrapping for Cointegrating Regressions", Statistics & Probability Letters, Vol. 83, pp. 474-480, 2013.
- [6] کاظمی، احد، «سیستم‌های قدرت الکتریکی جلد اول و دوم»، انتشارات دانشگاه علم و صنعت ایران، ۱۳۸۹.
- [7] Rukšenaite, J. and Vaitkus, P., "Prediction of Composite Indicators Using Combined Method of Extreme Learning Machine and Locally Weighted Regression", Nonlinear Analysis, Vol. 17, pp. 238-251, 2012.
- [8] MacKay, D. J., "Probable Networks and Plausible Predictions—a Review of Practical Bayesian Methods for Supervised Neural Networks", Network: Computation in Neural Systems, Vol. 6, pp. 469-505, 1995.
- [9] MacKay, D. J., "A Practical Bayesian Framework for Backpropagation Networks", Neural computation, Vol. 4, pp. 448-472, 1992.
- [10] Bates, B. C. and Campbell, E. P., "A Markov Chain Monte Carlo Scheme for Parameter Estimation and Inference in Conceptual Rainfall-Runoff Modeling", Water Resources Research, Vol. 37, pp. 937-947, 2001.
- [11] Lau, H. C., Ho, G. T., and Zhao, Y., "A Demand Forecast Model Using a Combination of Surrogate Data Analysis and Optimal Neural Network Approach", Decision Support Systems, Vol. 54, pp. 1404-1416, 2013.
- [12] Stewart, W. E., Caracotsios, M., and Sørensen, J. P., "Parameter Estimation from Multiresponse Data", AIChE Journal, Vol. 38, pp. 641-650, 1992.
- [13] Banerjee, S., Carlin, B. P., and E., A., "Gelfand, Hierarchical Modeling and Analysis for Spatial Data", Crc Press, 2014.
- [14] Kazemi, A., Rezaeipour, R., and Lashkarara, A., "Optimal Location of Rotary Hybrid Flow Controller (RHFC) Through Multi-Objective Mathematical Programming", Scientia Iranica, Vol. 19, pp. 1771-1779, 2012.
- [15] Núñez, J. J. J., "Particle Swarm Optimization Applications in Power System Engineering", University of Puerto Rico, Mayagüez Campus, 2004.
- [16] Rezaeipour, R., Kazemi, A., and Tayebi, M., "Operational Comparison of A New FACTS Controller (RHFC) With Other FACTS Devices Considering Modified Steady-State Model", Przegląd Elektrotechniczny, Vol. 88, pp. 54-58, 2012.
- [17] Power systems test case archive, <http://www.ee.washington.edu/research/pstca> [access ed: 21.01.2015].
- [18] Sabri, M., and Rezaeipour, R., "Improvement Estimation Power Flow Using Bayesian Neural Network", International Journal of Information Technology and Electrical Engineering, Vol 4, pp. 32-40, April 2015.
- [19] Manitsas, E., et al., "Distribution System State Estimation Using An Artificial Neural Network Approach for Pseudo Measurement Modeling", IEEE Transactions on Power Systems, Vol. 4, pp. 1888-1896, 2012.
- [20] Ashraf, M., et al., "Voltage Stability Monitoring of Power Systems Using Reduced Network and Artificial Neural Network", International Journal of Electrical Power & Energy Systems, Vol. 87, pp.43-51, 2017.
- [21] Lashkar Ara, A., Kazemi, A., and Nabavi Niaki, S.A., "Modelling of Optimal Unified Power Flow Controller (OUPFC) for Optimal Steady-State Performance of Power Systems", Energy Conversion and Management, Vol. 52, pp. 1325-1333, 2011.