

پیش بینی کوتاه مدت بار استان چهارمحال و بختیاری با استفاده از اجماع شبکه‌های عصبی

اسحاق فرجی^۱، محسن میرزائیانی^۲، حمید پروین^{۱،۲*}، علی چمکوری^۱، مجید محمدپور^{۱،۲}

^۱دانشگاه آزاد اسلامی، واحد خورموج - گروه برق و کامپیوتر parvin@iust.ac.ir

^۲باشگاه باشگاه پژوهشگران جوان و نخبگان، واحد نورآباد ممسنی، دانشگاه آزاد اسلامی، نورآباد ممسنی، ایران

^۲معاونت بهره برداری و دیسپاچینگ شرکت توزیع نیروی برق، استان چهارمحال و بختیاری

تاریخ دریافت: ۱۳۹۵/۷/۲۲ تاریخ پذیرش: ۱۳۹۶/۴/۲۱

چکیده

پیش‌بینی کوتاه مدت بار در بازار برق اهمیت زیادی دارد. از طرفی عوامل مهم تأثیرگذار بر پیش‌بینی کوتاه مدت بار به ویژگی‌های بار الکتریکی و آب و هوایی هر منطقه بستگی دارد، بنابراین با استفاده از داده‌های واقعی استان چهارمحال و بختیاری - شامل بار و دما - به پیش‌بینی کوتاه مدت بار الکتریکی استان پرداخته‌ایم. بدین منظور با استفاده از چهار روش مختلف شبکه عصبی پرسپترون (MLP)، مجمعی از شبکه عصبی پرسپترون (MLP Ensemble)، شبکه (Support Vector Machine) SVM و مجمعی از شبکه SVM به پیش‌بینی کوتاه مدت بار استان چهارمحال و بختیاری پرداختیم. نتایج حاصل از مقایسه این چهار روش نشان می‌دهد که مجمعی از شبکه عصبی پرسپترون بهترین روش به منظور پیش‌بینی کوتاه مدت بار می‌باشد.

کلیدواژه‌ها: پیش‌بینی کوتاه مدت بار، شبکه عصبی پرسپترون، مجمعی از شبکه عصبی پرسپترون.

۱- مقدمه

پیش بینی بار مصرفی به عنوان یک چالش در مجامع برق همواره مطرح بوده است. از آنجایی که میزان بار مصرفی در یک منطقه توسط یک سیستم تولید برق یکپارچه تامین می شود، این سیستم نیاز دارد که بدانند چه میزان بار الکتریکی باید تامین کند. چنان که سیستم بار کمتری تولید کند، کل سیستم دچار مخاطره شده و حتی بخشی از آن خاموش می شود. از طرفی به علت ناتوانی در ذخیره بار، تولید بیش از نیاز بار، باعث هدر رفتن آن بار می شود. نیاز به دانستن مقدار بار دقیق مصرفی یک منطقه، باعث دستیابی به بازدهی مطلوب در سیستم می شود.

نیازهای روزمره منطقه تحت پوشش بنا به پارامترهای گوناگون تغییر می کند. مثلاً در یک روز برفی، به علت نیاز بیشتر به انرژی، طبعاً مصرف بار الکتریکی افزایش می یابد. به علت وجود پارامترهای گوناگون دخیل در مسئله، میزان نیاز به بار مصرفی به شدت تغییر می کند. تغییر شدید این میزان مصرفی باعث می شود که کار مهندسين تولید بار، بسیار مشکل باشد؛ به گونه‌ای که آن‌ها برای جلوگیری از احتمال شکست یا خاموشی سیستم، بار بیشتری از آن مقدار باری که انتظار دارند مصرف شود، تولید می کنند. پس آن‌ها همواره درگیر پیش‌بینی بار مصرفی منطقه هستند. هر چه که پیش بینی آنها از بار مصرفی منطقه دقیق‌تر باشد، صرفه‌جویی در مصرف انرژی بهتر می‌باشد.

گاهی به‌جای پیش‌بینی مهندسين از میزان بار مصرفی، از یک مدل اتوماتیک کامپیوتری استفاده می شود. مدل پیش‌بینی می‌تواند از مدل‌های مبتنی بر یادگیری ماشین نیز باشند. بنا به این که پیش‌بینی ما برای چه مدت بعد است، مسئله کاملاً تغییر می‌کند. در این طرح به پیش‌بینی کوتاه مدت بار که در بازار برق اهمیت دارد پرداخته می‌شود. پیش‌بینی کوتاه مدت بار به پیش‌بینی بار از یک ساعت تا یک هفته آینده می‌پردازد.

به‌طور کلی پیش‌بینی بار برق مصرفی با استفاده از تکنیک‌های آماری و هوش مصنوعی انجام می‌شود. در تکنیک‌های آماری با استفاده از داده‌های گذشته و روابط ریاضی برای پیش‌بینی بار استفاده می‌شود. اما از آنجایی که رابطه بین بار و عوامل مؤثر بر آن، غیرخطی و بسیار پیچیده می‌باشد، با استفاده از روش‌های آماری که از روابط ریاضی برای پیش‌بینی بار استفاده می‌کنند نمی‌توان به نتایج مطلوبی رسید. در مقابل در تکنیک‌های هوش مصنوعی نحوه فکر کردن، استدلال و یادگیری انسان مورد استفاده قرار می‌گیرد [1]. در این روش‌ها، متغیر پیش‌بینی نتیجه قضاوت سیستم خبره از ورودی‌های منتخب با توجه به سابقه موجود این متغیر است [11]. به‌همین دلیل روش‌های هوش مصنوعی دارای توانایی بسیار بالایی در حل مسائل غیرخطی و بسیار پیچیده که با استفاده از روابط ریاضی قابل حل نیستند، می‌باشند.

در این طرح به پیش‌بینی کوتاه‌مدت بار با استفاده از روش‌های هوش مصنوعی پرداخته می‌شود. پیش‌بینی کوتاه‌مدت بار به پیش‌بینی بار از یک ساعت تا یک هفته آینده می‌پردازد. به‌طور کلی پیش‌بینی کوتاه مدت بار، در هماهنگی نیروگاه‌ها، عملکرد اقتصادی سیستم، طرح‌های انتقال انرژی و در کنترل زمان حقیقی سیستم از اهمیت بالایی برخوردار است. عملکرد اقتصادی همراه با قابلیت اطمینان برای یک سیستم قدرت، به طور زیادی بستگی به دقت پیش‌بینی بار دارد. به منظور دستیابی به هدف بیشینه کردن بازدهی عملکرد سیستم و یا به عبارتی کمینه کردن هزینه کلی سیستم، کارکرد صحیح توابعی شبیه اختصاص سوخت، هماهنگی واحدهای نیروگاهی و برنامه‌ریزی به منظور تعمیر و نگهداری الزامی است. کارکرد صحیح این توابع، در نتیجه پیش‌بینی دقیق بار حاصل می‌شود. تأثیر خطای زیاد در پیش‌بینی، باعث می‌شود که سیستم ما یا دارای عملکرد بیش از حد محتاط و یا دارای عملکرد بیش از حد ریسک‌پذیر باشد. تخمین بار بیش از حد واقعی، منجر به راه اندازی واحدهای زیادی از نیروگاه، خرید انرژی (سوخت) بیش از حد مورد نیاز و فراهم آوردن انرژی بیش از حد مورد نیاز مصرف می‌شود. همچنین تخمین بار کمتر از مقدار واقعی باعث آسیب پذیری سیستم می‌شود، که در نتیجه آن، با وارد کردن واحدهای اضطراری به منظور تأمین بارهای اضافی، هزینه بیشتری را (در مقایسه با عملکرد برنامه‌ریزی شده سیستم) به سیستم تحمیل می‌کند. بنابراین بهبود در دقت پیش‌بینی بار منجر به صرفه‌جویی در هزینه و افزایش امنیت سیستم می‌شود.

اغلب روش‌های پیش‌بینی از رهیافت‌های آماری یا الگوریتم هوش مصنوعی استفاده می‌کنند. بیشتر روش‌های اعمال شده رهیافت‌های باکس جنکیزه^۱، روش‌های نمایی و هالت-وینتر^۲ و شبکه‌های عصبی پایه گذاری شده بر روش‌ها می‌باشد و اخیراً نیز ماشین‌های

بردار پشتیبان^۳ (SVMs) مطرح شده است [12]. معرفی کاربرد سری‌های زمانی در بروک ول و دیویس^۴ در سال ۲۰۰۲ و یک بررسی بررسی کامل بر روی متدولوژی‌های مختلف پیش‌بینی بار در فین برگ و گنتلیو^۵ در سال ۲۰۰۵ مطرح شده است. اخیراً تحقیقات در این زمینه به کاربرد مدل‌های هوشمند دیگری نظیر بردار حمایت پیش‌بینی^۶ (SVR) نیز منجر شده است [5, 13]. این روش که مبتنی بر ماشین بردار پشتیبان (SVM) می‌باشد از قوی‌ترین مدل‌های پایه هوشمند می‌باشد. نتایج تجربی دال بر موفقیت این مدل در یادگیری داده‌های پیش‌بینی بار می‌باشد. در تحقیقات اخیر همچنین محققان از استفاده از مدل‌های پایه هوشمند به استفاده از مدل‌های هوشمند ترکیبی مهاجرت کرده‌اند [3, 14, 10, 8]. در حقیقت استفاده از مدل‌های هوشمند پایه، دیگر باعث بهبود در دقت پیش‌بینی نداشته؛ لذا محققان به دنبال آرایه روش‌های ترکیبی بوده‌اند تا از این منظر دقت پیش‌بینی بار را بهبود دهند. در اخیرترین کار از یک مبحث نو ظهور در الگوریتم‌های هوشمند ترکیبی به نام پیش‌بینی مبتنی بر اجماع^۷ نیز استفاده شده است و نشان داده شده است که دقت این روش در پیش‌بینی بار از دقت روش‌های پایه و اکثر روش‌های ترکیبی دیگر بهتر می‌باشد [6].

کاربرد این مقاله در تحلیل مسئله خاص پیش‌بینی کوتاه مدت بار و نشان دادن کارایی ترکیب مقدار زیادی از شبکه‌ها با هم در یک اجماع می‌باشد. اصطلاح "اجماع" یک گروه از ماشین‌های یادگیری که برای یک هدف کار می‌کنند را توصیف می‌کند، در مورد شبکه‌های عصبی بر روی داده‌های یکسان آموزش داده می‌شوند. با یکدیگر اجرا و خروجی‌شان به‌عنوان یک سیگنال با یکدیگر ترکیب می‌شوند [15]. در این کار، ما این متدولوژی را برای پیش‌بینی با هدف به‌دست آوردن یک پیش‌بینی قابل اطمینان، به‌کار گرفته‌ایم. بدین منظور با استفاده از چهار روش مختلف شبکه عصبی پرسپترون^۸ (MLP)، مجمعی از شبکه عصبی پرسپترون^۹ (MLP Ensemble)، شبکه SVM و مجمعی از شبکه SVM^{۱۰} به پیش‌بینی کوتاه مدت بار استان چهارمحال و بختیاری پرداختیم. این مقاله به صورت زیر آرایش یافته است: در بخش ۲ توصیفی از مدل‌های پیش‌بینی و اجماع شبکه‌های عصبی معرفی شده است. آزمایش‌ها و نتایج در بخش ۳ بیان می‌شوند و نهایتاً در بخش ۴ این مقاله به نتیجه‌گیری می‌پردازد.

۲- مدل‌های پایه

در این بخش به معرفی مدل‌های پایه‌ای استفاده شده در این طرح می‌پردازیم.

۲-۱ مدل شبکه‌های عصبی

شبکه‌های عصبی مصنوعی^{۱۱} (ANN) یا به زبان ساده‌تر شبکه‌های عصبی مدل محاسباتی نوینی است که برای یادگیری ماشینی، نمایش دانش، و در انتها اعمال دانش به دست آمده در جهت پیش‌بینی پاسخ‌های خروجی از سیستم‌های پیچیده. ایده اصلی این گونه شبکه‌ها (تا حدودی) الهام گرفته از شیوه کارکرد سیستم عصبی زیستی، برای پردازش داده‌ها، و اطلاعات به منظور یادگیری و ایجاد دانش قرار دارد. عنصر کلیدی این ایده، ایجاد ساختارهایی جدید برای سامانه پردازش اطلاعات است. این سیستم از شمار زیادی عناصر پردازشی فوق‌العاده بهم‌پیوسته با نام نرون تشکیل شده که برای حل یک مسأله با هم هماهنگ عمل می‌کنند و توسط سیناپس‌ها (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می‌کنند. در این شبکه‌ها اگر یک سلول آسیب ببیند بقیه سلول‌ها می‌توانند نبود آن را جبران کرده، و نیز در بازسازی آن سهیم باشند. این شبکه‌ها قادراند تا از روی نمونه‌هایی که قبلاً دیده‌اند، الگوهای حاکم بر این نمونه‌ها را فرا گیرند. مثلاً با اعمال سوزش به سلول‌های عصبی لامسه، سلول‌ها یاد می‌گیرند که به طرف جسم داغ نروند و با این

^۲ Holt-Winters

^۳ Support Vector Machines (SVMs)

^۴ Brockwell and Davis

^۵ Feinberg and Genethliou

^۶ Support Vector Regression (SVR)

^۷ Ensemble

^۸ Multi-Layer Perceptron (MLP)

^۹ Multi-Layer Perceptron Ensemble (MLP Ensemble)

^{۱۰} Support Vector Machines Ensemble (SVM Ensemble)


^{۱۱} Artificial Neural Network (ANN)

الگوریتم سیستم می‌آموزد که خطای خود را اصلاح کند. یادگیری در این سیستم‌ها به صورت تطبیقی صورت می‌گیرد، یعنی با استفاده از مثال‌ها وزن سیناپس‌ها به گونه‌ای تغییر می‌کند که در صورت دادن ورودی‌های جدید، سیستم پاسخ درست‌تری تولید کند. توافق دقیقی بر تعریف شبکه عصبی در میان محققان وجود ندارد؛ اما اغلب آنها موافق هستند که شبکه عصبی شامل شبکه‌ای از عناصر پردازش ساده (یا همان نورون‌ها) است، که می‌تواند رفتار پیچیده کلی تعیین شده‌ای از ارتباط بین عناصر پردازش و پارامترهای عنصر را نمایش دهد. منبع اصلی و الهام بخش برای این تکنیک، از آزمایش سیستم مرکزی عصبی و نورون‌ها (آکسون‌ها، شاخه‌های متعدد سلولهای عصبی و محل‌های تماس دو عصب) نشأت گرفته‌است، که یکی از قابل توجه‌ترین عناصر پردازش اطلاعات سیستم عصبی را تشکیل می‌دهد. در یک مدل شبکه عصبی، گره‌های ساده (بطور گسترده «نورون») برای تشکیل شبکه‌ای از گره‌ها، به هم متصل شده‌اند. به همین دلیل به آن، اصطلاح شبکه‌های عصبی اطلاق می‌شود. در حالی که یک شبکه عصبی نباید به خودی خود سازگارپذیر باشد، استفاده عملی از آن به واسطه الگوریتم‌هایی امکان پذیر است، که جهت تغییر وزن ارتباطات در شبکه (به منظور تولید سیگنال مورد نظر) طراحی شده باشد.

با استفاده از دانش برنامه‌نویسی رایانه می‌توان ساختار داده‌ای طراحی کرد که همانند یک نرون عمل نماید. سپس با ایجاد شبکه‌ای از این نورون‌های مصنوعی به هم پیوسته، ایجاد یک الگوریتم آموزشی برای شبکه و اعمال این الگوریتم به شبکه آن را آموزش داد. این شبکه‌ها برای تخمین^{۱۲} و تقریب^{۱۳} کارایی بسیار بالایی از خود نشان داده‌اند. گستره کاربرد این مدل‌های ریاضی بر گرفته از عملکرد مغز انسان، بسیار وسیع می‌باشد که به عنوان چند نمونه کوچک می‌توان استفاده از این ابزار ریاضی در پردازش سیگنال‌های بیولوژیکی، مخابراتی و الکترونیکی تا کمک در نجوم و فضا نوردی را نام برد.

شکل ۱ شمای شبکه پرسپترون سه لایه نشان می‌دهد. همان گونه که در این شکل مشخص است هر نرون در هر لایه، به تمامی نرون‌های چند لایه قبل متصل می‌باشد. به چنین شبکه‌هایی، شبکه‌های کاملاً مرتبط^۱ گویند. شبکه فوق، عملاً از به هم پیوستن سه شبکه پرسپترون تک لایه ایجاد شده است، یعنی لایه خروجی و دو قسمت دیگر لایه‌های میانی نامیده می‌شوند. خروجی‌های لایه اول، بردار ورودی لایه دوم را تشکیل می‌دهند، و به همین ترتیب بردار خروجی لایه دوم، ورودی‌های لایه سوم را می‌سازند، و خروجی‌های لایه سوم، پاسخ واقعی شبکه را تشکیل می‌دهند. به عبارتی روشن‌تر، روند جریان سیگنالی در شبکه، در یک مسیر پیشخور صورت می‌گیرد (از چپ به راست از لایه‌ای به لایه دیگر).

اگر یک شبکه را هم‌ارز با یک گراف بدانیم، فرآیند آموزش شبکه تعیین نمودن وزن هر یال و بایاس اولیه خواهد بود.



شکل ۱: نمونه‌ای از شبکه‌های عصبی با سه لایه از نرون‌ها

از قرن نوزدهم به طور همزمان اما جداگانه از سوی نروفیزیولوژیست‌ها سعی کردند سیستم یادگیری و تجزیه و تحلیل مغز را کشف کنند، و از سوی دیگر ریاضیدانان تلاش کردند تا مدل ریاضی بسازند، که قابلیت فراگیری و تجزیه و تحلیل عمومی مسائل را دارا باشد. اولین کوشش‌ها در شبیه‌سازی با استفاده از یک مدل منطقی توسط مک‌کلوج و پیتز انجام شد که امروزه بلوک اصلی سازنده اکثر شبکه‌های عصبی مصنوعی است. این مدل فرضیه‌هایی در مورد عملکرد نورون‌ها ارائه می‌کند. عملکرد این مدل مبتنی بر جمع

ورودی‌ها و ایجاد خروجی است. چنانچه حاصل جمع ورودی‌ها از مقدار آستانه بیشتر باشد اصطلاحاً نورون برانگیخته می‌شود. نتیجه این مدل اجرای توابع ساده مثل AND و OR بود.

نه تنها نروفیزیولوژیست‌ها بلکه روان‌شناسان و مهندسان نیز در پیشرفت شبیه‌سازی شبکه‌های عصبی تاثیر داشتند. در سال ۱۹۵۸ شبکه پرسپترون توسط روزنبلات معرفی گردید. این شبکه نظیر واحدهای مدل شده قبلی بود. پرسپترون دارای سه لایه می‌باشد، به همراه یک لایه وسط که به عنوان لایه پیوند شناخته شده است. این سیستم می‌تواند یاد بگیرد که به ورودی داده شده خروجی تصادفی متناظر را اعمال کند. سیستم دیگر مدل خطی تطبیقی نورون می‌باشد که در سال ۱۹۶۰ توسط ویدرو و هاف در دانشگاه استنفورد به وجود آمد که اولین شبکه‌های عصبی به کار گرفته شده در مسائل واقعی بودند. Adalaline یک دستگاه الکترونیکی بود که از اجزای ساده‌ای تشکیل شده بود، روشی که برای آموزش استفاده می‌شد با پرسپترون فرق داشت.

در سال ۱۹۶۹ میسکی و پاپرت کتابی نوشتند که محدودیت‌های سیستم‌های تک لایه و چند لایه پرسپترون را تشریح کردند. نتیجه این کتاب پیش داوری و قطع سرمایه‌گذاری برای تحقیقات در زمینه شبیه‌سازی شبکه‌های عصبی بود. آنها با طرح اینکه طرح پرسپترون قادر به حل هیچ مساله جالبی نمی‌باشد، تحقیقات در این زمینه را برای مدت چندین سال متوقف کردند.

با وجود این که اشتیاق عمومی و سرمایه‌گذاری‌های موجود به حداقل خود رسیده بود، برخی محققان تحقیقات خود را برای ساخت ماشین‌هایی که توانایی حل مسائلی از قبیل تشخیص الگو را داشته باشند، ادامه دادند. از جمله گراسبگ که شبکه‌ای تحت عنوان Avalanch را برای تشخیص صحبت پیوسته و کنترل دست ربات مطرح کرد. همچنین او با همکاری کارپنتر شبکه‌های ART را بنا نهادند که با مدل‌های طبیعی تفاوت داشت. اندرسون و کوهنون نیز از اشخاصی بودند که تکنیک‌هایی برای یادگیری ایجاد کردند. وریاس در سال ۱۹۷۴ شیوه آموزش پس انتشار خطا را ایجاد کرد که یک شبکه پرسپترون چندلایه البته با قوانین نیرومندتر آموزشی بود.

پیشرفت‌هایی که در سال ۱۹۷۰ تا ۱۹۸۰ بدست آمد برای جلب توجه به شبکه‌های عصبی بسیار مهم بود. برخی فاکتورها نیز در تشدید این مساله دخالت داشتند، از جمله کتاب‌ها و کنفرانس‌های وسیعی که برای مردم در رشته‌های متنوع ارائه شد. امروز نیز تحولات زیادی در تکنولوژی ANN ایجاد شده است.

۲-۲ ماشین بردار پشتیبان

ماشین بردار پشتیبانی (SVM) یکی از روش‌های یادگیری با نظارت است که از آن برای طبقه‌بندی و رگرسیون استفاده می‌کنند. این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی از جمله شبکه‌های عصبی پرسپترون نشان داده است. مبنای کاری دسته‌بندی کننده SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌کنیم خطی را انتخاب کنیم که حاشیه اطمینان بیشتری داشته باشد. حل معادله پیدا کردن خط بهینه برای داده‌ها به وسیله روش‌های برنامه‌ریزی مرتبه دو^{۱۴} که روش‌های شناخته شده‌ای در حل مسائل محدودیت‌دار هستند صورت می‌گیرد. قبل از تقسیم خطی برای اینکه ماشین بتواند داده‌های با پیچیدگی بالا را دسته‌بندی کند داده‌ها را به وسیله تابع کرنل به فضای با ابعاد خیلی بالاتر می‌بریم. برای اینکه بتوانیم مساله ابعاد خیلی بالا را با استفاده از این روش‌ها حل کنیم از قضیه دوگانگی لاگرانژ برای تبدیل مساله مینیمم‌سازی مورد نظر به فرم دوگانگی آن که در آن به جای تابع پیچیده کرنل که ما را به فضایی با ابعاد بالا می‌برد، تابع ساده‌تری به نام تابع هسته که ضرب برداری تابع کرنل است ظاهر می‌شود استفاده می‌کنیم. از توابع هسته مختلفی از جمله هسته‌های نمایی، چندجمله‌ای و سیگموئید می‌توان استفاده نمود.

آموزش نسبتاً ساده است برخلاف شبکه‌های عصبی در ماکزیمم‌های محلی گیر نمی‌افتد. برای داده‌های با ابعاد بالا تقریباً خوب جواب می‌دهد. مصالحه بین پیچیدگی دسته‌بندی کننده و میزان خطا به طور واضح کنترل می‌شود. به یک تابع کرنل خوب و انتخاب پارامتر C نیاز دارد.

۲-۳ مدل ترکیبی

مدل‌های جمعی یا مدل‌های ترکیبی مدلهایی هستند که از یک یا چند مدل آموزش یافته شده رای عمل نظردهی استفاده می‌کند و از نظریه توافقی آن‌ها به‌عنوان نظریه نهایی بهره می‌برد. این نظریه هم‌چون نظریه مجمع در فقه است. نظری که غالب است، نظر توافقی نامیده می‌شود. برای روشن شدن مطلب، فرض کنید که هر مدلی که آموزش داده‌ایم، را M نشان دهیم؛ مدل I -ام را با M_i نشان می‌دهیم. خروجی مدل M_i بر روی داده J -ام (یعنی داده (x_j)) را با $M_i(x_j)$ نشان می‌دهیم. ساده‌ترین مدل مجمع، نظریه مجمع میانگین است. در این نظریه، رای توافقی جمع از رابطه زیر به دست می‌آید.

$$E(x_j) = \frac{1}{B} \sum_{i=1}^B M_i(x_j) \quad (1)$$

که در رابطه (۱) $E(x_j)$ نشان دهنده خروجی جمع مدل‌های آموزش دیده است؛ تعداد مدل‌های جمع، B تا است. روش دیگر میانه است که از رابطه (۲) به دست می‌آید.

$$E(x_j) = \text{median}(M_i(x_j)) \quad (2)$$

روش دیگر میانگین وزن دار است که از رابطه (۳) به دست می‌آید.

$$E(x_j) = \frac{1}{\sum_{p=1}^B w_p} \sum_{i=1}^B w_i M_i(x_j) \quad (3)$$

w_i وزن رده‌بند I -ام را نشان می‌دهد. این روش از روش‌های دیگر بهتر است. در این جا تنها مشکلی که وجود دارد، تعیین وزن مناسب w_i برای هر مدل است. کنچوا نشان داده است (۲۰۱۴) که این وزن در حالت بهینه از رابطه زیر به دست می‌آید.

$$w_i = \log\left(\frac{p_i}{1-p_i}\right) \quad (4)$$

که p_i نشان دهنده دقت مدل I -ام است. ما در این تحقیق از این مدل برای مجمع بهره برده‌ایم.

یک مجمع به تنوع آراء، به‌طور اساسی نیاز دارد، یعنی اگر یک مجمع از مدل‌ها بخواهند به‌عنوان یک مدل جمعی خوب باشد، آن‌ها باید به اندازه کافی متنوع باشند تا خطای همدیگر را بپوشانند. بنابراین در حین ساخت یک مجمع به یک مکانیسم برای تضمین متنوع بودن مجمع نیاز داریم. بعضی مواقع این مکانیسم این گونه است که یک زیر مجموعه از مدل‌های پایه تولید شده را با هدف نگهداری تنوع در مجمع انتخاب/حذف شوند. در یادگیری مبتنی بر مجمع این امکان وجود دارد که داده‌ها به بخش‌های به مراتب کوچکتری شکسته شوند و مدل‌های ساده و سریعی بر هر کدام از این بخش‌ها ایجاد شده و مدل جمعی نهایی (مدل جمع‌کننده نهایی) را نیز با یک روش بدون سربار زمانی چشمگیر به انجام رساند.

از آنجایی که ایجاد مدل مهم‌ترین وظیفه عدم تشخیص الگو می‌باشد، بنابراین از همان شروع علم تشخیص الگو مهم‌ترین چالش مجامع تشخیص الگو این بوده است که یک مدل عمومی را برای یادگیری هر مسئله یا مجموعه داده‌ای معرفی کنند. برای یادگیری یک مجموعه داده همیشه مطلوب است که یک مدل مناسب استفاده شود. از آنجایی که رویکرد یافتن بهترین مدل برای یک مسئله خاص غیرعملی است، یک رویکرد دیگر استفاده می‌شود. رویکرد دیگر این است که تعدادی مدل نامطلوب را به عنوان یک مجمع استفاده کنیم. یادگیری جمعی یک رویکرد قدرتمند برای فراهم نمودن یک سیستم مدل نزدیک به بهینه برای هر مسئله‌ای می‌باشد. به‌طور کلی این جمله همیشه درست است که ترکیب مدل‌های متنوع منجر به افزایش کارایی مدل می‌شود. این نشان از اهمیت تنوع در موفقیت یک مجمع می‌باشد. تنوع در میان مدل‌های پایه یک مجمع حاکی از استقلال آن مدل‌ها می‌باشد. این بدان معنی می‌باشد که اشتباه در مدل‌های پایه هم‌زمان بر روی یک الگو رخ نخواهند داد. کنچوا به صورت تئوری و تجربی نشان داده است که جمعی از تعدادی مدل پایه همیشه دقت مدل را بهتر می‌کند مشروط به اینکه مدل‌های پایه مستقل باشند. هم‌چنین نشان داده شده است که فلسفه مجمع قابل اعمال به شبکه بیزی نیز می‌باشد.

کنچوا یک دسته از روش‌ها برای اندازه‌گیری تنوع موجود در یک مجمع پیشنهاد داده است و سپس بر اساس یک روش جستجو، یک مدل ساخت مجمع متنوع ارائه کرده است.

قابل اثبات است که هر چه تعداد مدل‌های پایه در سیستم بیشتر شود خروجی سیستم و تصمیم اتخاذ شده دارای دقت بیشتری است. این توصیف زمانی برقرار است که دقت مدل‌ها (احتمال تشخیص درست توسط هر مدل) نسبت به یکدیگر مستقل خطی باشد. در غیراین صورت یعنی اگر دقت آن‌ها وابسته باشد مثلاً در بدترین شرایط مدل‌ها مشابه باشند برای هر ورودی دلخواه قطعاً خروجی

همه مدل‌ها یکسان است؛ در نتیجه رای گیری یک امر بیهوده است و در نتیجه دقت مدل ترکیبی همان دقت مدل پایه است. پس باید اول مدل‌های پایه مورد استفاده دارای دقت بالایی باشند (بهتر از تصادفی باشند)، ثانيا دارای تنوع نیز باشند (همگی مستقل باشند و تا حد ممکن مثل هم نباشند).

۳- پیاده سازی روش های مختلف

داده‌هایی را که به منظور پیش‌بینی بار مورد نیاز می باشد را می توان به دو دسته عمده، اطلاعات بار مربوط به سال‌های قبل و اطلاعات آب و هوایی این سال‌ها تقسیم کرد. در این طرح از داده‌های بار و دمای سال‌های ۸۸ تا ۹۱ به عنوان داده‌های آموزش و از داده‌های ۵ ماه اول سال ۹۲، به عنوان داده‌های تست استفاده شده است (دقت شود که داده‌های سه سال اخیر برای ارزیابی روش پیشنهادی در دسترس نبوده‌اند). به منظور در نظر گرفتن شرایط آب و هوایی باید مهمترین عوامل آب و هوایی که در مسئله مصرف بار دخیل‌اند، در نظر گرفته شوند. دما مؤثرترین عامل آب و هوایی، در مصرف بار الکتریکی می‌باشد. بنابراین داده‌های اصلی مورد نیاز همان اطلاعات بار روزانه مربوط به سال‌های قبل و اطلاعات دمای روزانه همان سال‌ها می‌باشد. مسئله مهم دیگر، منطقه مورد نظر و یا ایستگاه هواشناسی است که بتواند بیان کننده درجه حرارت کل استان باشد. به همین دلیل اطلاعات آب و هوایی مورد نیاز از سه ایستگاه واقع در استان یعنی ایستگاه‌های شهرکرد، کوهرنگ و لردگان تهیه شده‌اند که تا حدود زیادی می‌تواند بیان کننده درجه حرارت کل استان باشد.

به‌طور کلی، به منظور انتخاب تعداد متغیرهای ورودی دو روش وجود دارد، یکی بر اساس تجربه و دیگری بر اساس روش‌های آماری. بر اساس کار تحقیقاتی که در خصوص انتخاب ورودی با استفاده از مقالات مختلف، به خصوص مقالاتی که به پیش‌بینی بار ساعتی در شبکه برق ایران می‌پردازد و همچنین با استفاده از سعی و خطا در انتخاب ورودی‌ها و آموزش و تست شبکه، ۱۸ ورودی به صورت جدول ۱ به عنوان ورودی برای شبکه عصبی انتخاب شده است.

جدول ۱: ۱۸ ورودی مختلف شبکه عصبی طراحی شده به منظور پیش بینی بار

تقسیم بندی بر اساس	ورودی ها	تعداد ورودی‌ها
نوع روز	نوع روز هفته، نوع روز سال	۲
دمای روز گذشته*	حداکثر دمای ایستگاه‌های کوهرنگ، شهرکرد و لردگان	۳
دمای پیش بینی شده**	حداکثر و دمای پیش‌بینی شده ایستگاه‌های کوهرنگ، شهرکرد و لردگان	۳
بار ساعات گذشته	۱۰۱۶۹، ۱۶۸، ۱۶۷، ۴۹، ۴۸، ۴۷، ۲۵، ۲۴، ۲۳ ساعت گذشته	۱۰

* دمای روز گذشته: دمای روز قبل از پیش‌بینی است.

** دمای پیش بینی شده: دمای روزی که قرار است بار آن پیش‌بینی شود.

جهت انتخاب ورودی های شبکه عصبی از بین ویژگی های مهم در مسئله پیش بینی بار لازم است وابستگی این ویژگی ها را نسبت به خروجی شبکه سنجید. همچنین بین این ویژگی ها ممکن است وابستگی بالایی وجود داشته باشد که در این صورت می توان از یکی از ویژگی ها صرف نظر کرد. تحلیل همبستگی ابزاری برای تعیین نوع و درجه رابطه یک متغیر کمی با متغیر کمی دیگر است. ضریب همبستگی یکی از معیارهای مورد استفاده در تعیین همبستگی دو متغیر می باشد. جهت تعیین ضریب همبستگی دو ویژگی عددی A و B از رابطه زیر استفاده می شود:

$$r_{A,B} = \frac{\sum_{i=1}^N (a_i b_i) - N \bar{A} \bar{B}}{N \sigma_A \sigma_B} \quad (5)$$

در این رابطه N تعداد نمونه های دوتایی، a_i و b_i مقادیر مربوطه در دوتایی i ام، \bar{A} و \bar{B} مقادیر متوسط مربوط به A و B، σ_A و σ_B انحراف های مربوط به A و B و $\sum_{i=1}^N (a_i b_i)$ مجموع حاصلضرب نقطه‌ای AB می باشد. (برای هر دوتایی مقدار A در مقدار B در آن دوتایی مربوطه ضرب می شود). لازم به ذکر است $-1 \leq r_{A,B} \leq 1$. اگر $r_{A,B}$ بزرگتر از صفر باشد همبستگی بین A و B

مثبت است به این معنی که رابطه مستقیمی بین A و B وجود دارد. مقادیر بالاتر $r_{A,B}$ همبستگی بیشتر را نشان می دهد. همچنین مقادیر بالاتر وابستگی نشان می دهد که می توان از یکی از دو ویژگی A و B صرفنظر نمود. اگر ضریب همبستگی برابر صفر شود به این معنی است که A و B مستقل از یکدیگرند و بین آن ها وابستگی وجود ندارد. اگر مقدار ضریب همبستگی کمتر از صفر شود A و B وابستگی منفی دارند به این معنی که بین A و B رابطه معکوس وجود دارد. به عبارت دیگر وقتی مقدار یکی از ویژگی ها افزایش می یابد مقدار ویژگی دیگر کاهش می یابد.

به منظور دسته بندی داده ها، داده های بار روزانه استان را می توان از جنبه های گوناگون (مثلاً) بر اساس نوع روز هفته و نوع روز (سال) طبقه بندی کرد. در این مقاله روزهای هفته به ۴ نوع روز کاری تقسیم شده است. به عبارت دیگر ورودی نوع روز هفته چهار حالت دارد: (۱) شنبه به عنوان اولین روز کاری، (۲) یکشنبه تا چهارشنبه به عنوان روزهای کاری عادی، (۳) پنجشنبه آخرین روز کاری (روز قبل از تعطیلی) و (۴) جمعه روز تعطیل. ایام سال نیز به ۱۱ حالت مختلف به صورت زیر تقسیم شده است. ۱۱ حالت مختلف ایام سال عبارتند از: روز عادی، اولین روز سال، عید نوروز، روز جمهوری اسلامی، روز طبیعت، رحلت حضرت امام خمینی، قیام خونین ۱۵ خرداد، ۲۲ بهمن پیروزی انقلاب اسلامی، ۲۹ اسفند روز ملی شدن صنعت نفت، ماه رمضان و مراسمات مذهبی.

به دلیل این که توابع مورد استفاده در شبکه عصبی از قبیل تابع محرک خطی، توابع سیگموئید، و غیره، همگی حداکثر در محدوده -1 تا $+1$ می باشند، لذا ضروری است تا داده های جمع آوری شده را نیز به گونه ای نرمالیزه کرد، که همگی آنها در بازه -1 تا $+1$ قرار گیرند. این کار به منظور جلوگیری از اشباع شدن خروجی شبیه سازی شده صورت می گیرد؛ چرا که در ناحیه اشباع توابع، یک تغییر در مقدار ورودی منجر به تغییرات بسیار کم در خروجی می شود. توابع انتقالی که انتخاب شده اند همگی در بازه -1 و $+1$ قرار دارند، بنابراین با استفاده از روش مینیمم - ماکزیمم، تمامی داده های بار و دما در ساعت های گوناگون، با استفاده از رابطه زیر نرمالیزه شده اند:

ضریب همبستگی دو ویژگی عددی A و B از رابطه زیر استفاده می شود:

$$X_{\text{normalized}} = \frac{X_{\text{actual}} - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \times 2 - 1 \quad (6)$$

$X_{\text{normalized}}$ و X_{actual} ، X_{max} ، X_{min} به ترتیب مقادیر مینیمم واقعی، ماکزیمم واقعی، داده واقعی، داده نرمالیزه شده آن داده واقعی می باشد. مثلاً در داده های دما، X_{actual} ، X_{max} ، X_{min} و $X_{\text{normalized}}$ به ترتیب مقادیر مینیمم دمای ممکن، ماکزیمم دمای ممکن، یک دمای واقعی و دمای نرمالیزه شده آن دمای واقعی است.

بعد از مشخص شدن ساختار مدل، باید مدل مورد نظر آموزش داده شود. در این گزارش از شبکه پرسپترون، شبکه SVM، مجموعی از شبکه های پرسپترون و مجموعی از شبکه های SVM استفاده شده است. همه این الگوریتم ها در نرم افزار MATLAB پیاده سازی شده اند.

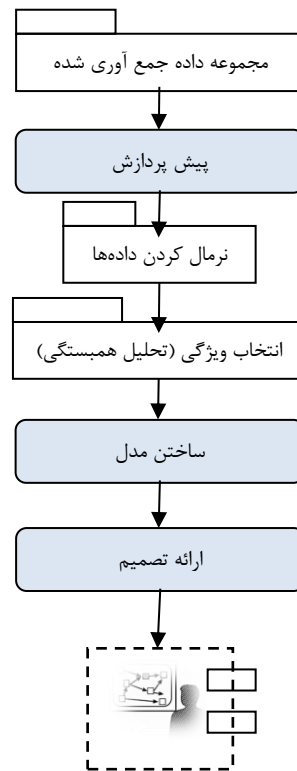
به منظور آزمایش شبکه، معیارهای مختلفی وجود دارد در این طرح از معیار درصد قدرمطلق میانگین خطا (MAPE) استفاده می شود. تعریف درصد قدرمطلق میانگین خطا به صورت زیر می باشد:

$$MAPE(\%) = \frac{1}{N} \sum_{i=1}^N \frac{|P_A^i - P_F^i|}{P_A^i} \times 100 \quad (7)$$

در این جا P_A بار واقعی، P_F بار پیش بینی شده و N تعداد ساعت های پیش بینی شده می باشد. هم چنین درصد خطا در هر ساعت $\varepsilon(\%)$ ، به صورت زیر تعریف می شوند:

$$\varepsilon(\%) = \frac{P_A^i - P_F^i}{P_A^i} \times 100 \quad (8)$$

برای بهتر نشان دادن مراحل روش های ارائه شده از یک روندنما (فلوچارت) استفاده شده است. روندنمای روش پیشنهادی در حالت کلی در شکل ۲ ترسیم شده است.



شکل ۲: روندنمای روش پیشنهادی

۲-۳ نتایج حاصل از پیاده سازی روش های مختلف

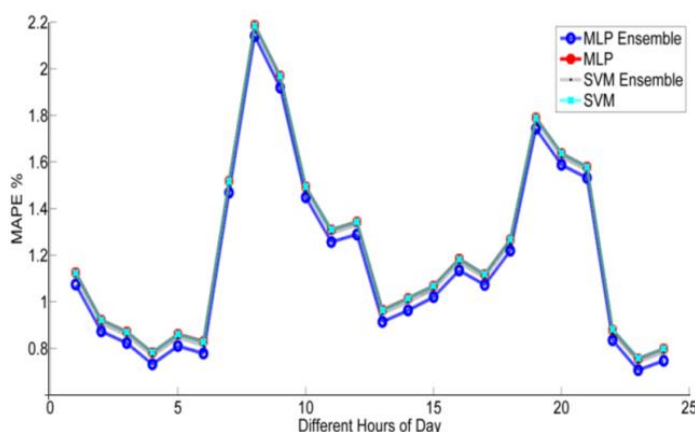
در صورتی که در هر جای مقاله، پارامترها صریحا ذکر نشود، از پارامترهای پیش فرض استفاده شده است. پارامتر تعداد لایه‌های شبکه عصبی پیش فرض، سه بوده است. لایه اول ۱۰ نرون با تابع فعالیت سیگموئید است. لایه دوم ۵ نرون با تابع فعالیت خطی است. لایه سوم یک نرون با تابع فعالیت سیگموئید است. تعداد اپوک (تکرار) مورد نیاز، ۴۹۲ در نظر گرفته شده است. با استفاده از چهار روش مختلف شبکه عصبی پرسپترون، مجمعی از شبکه عصبی پرسپترون، شبکه SVM و مجمعی از شبکه SVM به پیش بینی کوتاه مدت بار استان چهارمحال و بختیاری پرداختیم. نتایج حاصل از مقایسه این چهار روش که در جدول ۲ و نمودارهای ۲ تا ۴ آمده است، نشان می دهد که مجمعی از شبکه عصبی پرسپترون بهترین روش به منظور پیش بینی کوتاه مدت بار می باشد. جدول ۲ مقدار درصد خطای MAPE مربوط به چهار روش مختلف پیش بینی را نشان می دهد. همانطور که از جدول معلوم است خطای پیش بینی با استفاده از روش MLP Ensemble کمترین مقدار را دارد. شکل ۳ نیز منحنی خطای هر ساعت از شبانه روز با استفاده از چهار روش مختلف را نشان می دهد، همان طور که از منحنی‌ها مشخص است روش MLP Ensemble کمترین مقدار خطا را در هر ساعت از شبانه روز دارد. شکل ۴ منحنی مقدار متوسط خطای ساعات شبانه روز در ۵ ماه اول سال ۱۳۹۲ با استفاده از چهار روش مختلف را نشان می دهد که نیز تایید کننده برتری روش مجمعی از شبکه عصبی پرسپترون نسبت روش های دیگر می باشد.

جدول ۲: مقدار درصد خطای MAPE چهار روش مختلف پیش بینی کوتاه مدت بار


Method	MLP Ensemble	SVM	SVM Ensemble	MLP
MAPE%	1.17	1.20	1.21	1.22

اگر چه روشهای جمعی پیشنهادی از نظر دقت در جدول ۲، بهتر از سایر روش‌ها بوده است، لیکن هنوز نمی توان ادعایی دال بر این که بهترین روش کدام است داشت. باید دید که آیا این نتایج تصادفی نبوده باشد که با تغییر دوباره پارامترها و مقداردهی اولیه متفاوت الگوریتم‌ها، نتایج به گونه‌ای دیگر رقم نخواهد خورد. برای بررسی دقیق تر و پی بردن به این نکته که آیا این برتری بامعنی است، باید به

یکی از روش‌های راستی‌سنجی آماری پناه برد. در این جا از روش راستی‌سنجی آماری t-test استفاده کرده‌ایم و آزمایشات را ۳۰ بار تکرار کرده‌ایم. نتایج این تست نشان داد که اختلاف این روش‌ها با اطمینان ۹۵ درصد بامعنی است. لازم به ذکر است شبکه RBF بر روی داده‌های پیش‌بینی کوتاه مدت بار به‌علت زیاد بودن داده‌های آموزشی و نبودن نظم کافی در داده‌ها همگرا نشد. همچنین شبکه SVM به‌دلیل پایدار بودن و همگرا شدن در اجراهای گوناگون به یک خروجی یکسان، موجب عدم وجود تنوع لازم برای ساخت یک مجمع موفق شد که این مسئله باعث پایین ماندن دقت مجمعی از شبکه SVM نسبت به مجمع شبکه عصبی پرسپترون شد هر چند که دقت شبکه SVM نسبت به شبکه پرسپترون چند لایه کارایی بالاتری دارد. شبکه SVM مورد استفاده از پارامتر نرمی ۲ بهره گرفته است و تعداد رده‌بندهای یادگیر موجود در مجمع ۵۱ رده‌بند می‌باشد. همچنین شبکه عصبی پرسپترون از سه لایه و به ترتیب با تعداد نرون های ۱۰، ۵ و ۱ در هر لایه می‌باشد.



شکل ۳: منحنی خطای هر ساعت از شبانه روز با استفاده از چهار روش مختلف




شکل ۴: منحنی مقدار متوسط خطای ساعات شبانه روز در ۵ ماه اول سال ۱۳۹۱ با استفاده از چهار روش مختلف

۲-۳ نتایج حاصل از روش انتخاب شده


در شکل ۵ خطای اجماع ۲۰ شبکه عصبی پرسپترون بر روی داده‌های ۵ ماه اول سال ۹۱، با داده‌های آموزشی سال‌های ۸۸-۹۰ به تفکیک ماه‌های سال ارائه شده است. به طوری که خطای متوسط تمام ساعات همه روزهای ماه فروردین در اولین میله از سمت چپ نمایش داده شده است.

در شکل ۶ خطای اجماع ۲۰ شبکه عصبی پرسپترون بر روی ۵ ماه اول داده‌های سال ۹۱، با داده‌های آموزشی سال‌های ۸۸-۹۰ به تفکیک ساعات شبانه روز ارائه شده است. به طوری که خطای متوسط تمام ساعات اول تمام روزهای ۵ ماه اول سال ۹۱ در اولین میله از سمت چپ نمایش داده شده است.

متوسط کلی خطاهای به دست آمده در همه ساعات همه روزهای سال ۹۱ با اعمال اجماع ۲۰ شبکه عصبی پرسپترون ، ۱،۱۷٪ است.



شکل ۵: خطای اجماع ۲۰ شبکه عصبی پرسپترون به تفکیک ماه های سال



شکل ۶: خطای اجماع ۲۰ شبکه عصبی پرسپترون به تفکیک

۴. نتیجه گیری

در این مقاله پیش‌بینی کوتاه مدت بار در استان چهارمحال و بختیاری با روش‌های یادگیری ماشین انجام شده است. در این کار، ابتدا ۳۰ ویژگی‌های گوناگون استخراج می‌شود. داده‌های گوناگون به دو دسته کلی آموزشی و آزمایشی تقسیم می‌شوند. ۳ سال از داده‌ها به عنوان داده‌های آموزشی و ۵ ماه از سال چهارم به عنوان داده‌های آزمایشی در نظر گرفته می‌شوند. سپس با روش‌های تحلیل همبستگی بر روی داده‌های آموزشی، مرحله انتخاب ویژگی‌ها انجام می‌شود. پس از انجام مرحله انتخاب ویژگی‌ها، فقط ۱۸ ویژگی انتخاب می‌شود. در مرحله بعد با کمک چندین روش یادگیری در ماشین مجموعه داده آموزشی آماده شده، فراگرفته می‌شود. پس از ارزیابی این روش‌ها به کمک معیارهای متعارف بر روی داده‌های آزمایشی، مشخص می‌شود که روش‌های یادگیری SVM بهتر از شبکه‌های عصبی MLP عمل می‌نمایند. همچنین شبکه SVM به دلیل پایدار بودن و همگرا شدن در اجراهای گوناگون به یک خروجی یکسان، موجب عدم وجود تنوع لازم برای ساخت یک مجمع موفق شد که این مسئله باعث پایین ماندن دقت مجمعی از شبکه SVM نسبت به مجمع شبکه عصبی پرسپترون شد هرچند که دقت شبکه SVM نسبت به شبکه پرسپترون چند لایه کارایی بالاتری دارد. همچنین روش‌های جدید یادگیری ترکیبی که کارایی خود را در یادگیری ماشین نسبت به روش‌های یادگیری ساده نشان داده‌اند را نیز در این زمینه مورد تحلیل قرار می‌دهیم. پس از ارزیابی‌های جدید پی می‌بریم که روش یادگیری ترکیبی باعث بهبود در نتایج می‌شود. روش یادگیری ترکیبی MLP بهترین نتایج را در این داده‌ها نشان می‌دهد. این نتایج خطایی معادل ۱،۱۷٪ را نشان می‌دهد. این خطا نشان می‌دهد، این خطا بهتر از معیار خطای قابل قبول در شرکت برق استان شهرکرد است. چنان که از این روش بتوان در عمل استفاده کرد، نسبت به روش‌های دیگری که در حال حاضر در این استان مورد استفاده است، باعث صرفه‌جویی در تولید برق در استان می‌شود.

تشکر و قدردانی

از شرکت توزیع نیروی برق استان چهار محال و بختیاری به دلیل در اختیار گذاشتن اطلاعات و داده ها و همکاری در انجام این طرح تحقیقاتی تشکر و قدردانی می نمایم.

مراجع

- [1] سرلک، م.، ابراهیمی، ت.، توکلی، ا.، طلوع خیامی، م. و مقدس انگیزان، د. استفاده از شبکه‌های عصبی برای پیش‌بینی کوتاه مدت بار. بیست و پنجمین کنفرانس بین‌المللی برق، ۱۳۸۹.
- [2] Amirarfaei, F., Menhaj, M.B and Barghinia, S., "A Combination of Pruning algorithm and Parallel Networks Structure to Increase the Generalization of Neural Networks Used for Short-Term Load Forecasting of Iran Power System", IEEE Int. conf. Asia-Pacific Power and Energy Engineering Conference (APPEEC, 2010), pp. 1-4.
- [3] Amjady, N., " Short-term bus load forecasting of power systems by a new hybrid method" ,IEEE Trans. Power Syst., vol. 22, no. 1, Feb. 2007, pp. 333–341.
- [4] Brockwell, P. J., Davis, R. A., "Introduction to Time Series and Forecasting", Berlin: Springer-Verlag, Mar. 2002.
- [5] Elattar, E. E., Goulermas, J. Y., Wu, Q. H., "Electric load forecasting based on locally weighted support vector regression" ,IEEE Trans. Syst., Man Cyber. C, Appl. Rev., vol. 40, no. 4, July 2010, pp. 438–447.
- [6] Felice, M. D., Yao, X., "Short-Term Load Forecasting with Neural Network Ensembles: A Comparative Study" , IEEE Computational Intelligence Magazine, July 2011, pp. 47-56.
- [7] Farhadi, M and Moghaddas-Tafreshi S.M., "Analysis of Effective Variables on Daily Electrical Load Curves of Iran Power Network", IEEE Int. conf. Industrial Technology, 2008, pp. 1-7.
- [8] Fan, S., Chen, L., "Short-term load forecasting based on an adaptive hybrid method " ,IEEE Trans. Power Syst., vol. 21, no. 1, 2006, pp. 392–401.
- [9] Feinberg, E. A., Genethliou, D., "Load forecasting", in Applied Mathematics for Restructured Electric Power Systems: Optimization, Control, and Computational Intelligence, J. Chow, F. Wu, and J. Momoh, Eds. Berlin: Springer-Verlag, 2005, pp. 269–285.
- [10] Hinojosa, A., Hoese, V. H., "Short-term load forecasting using fuzzy inductive reasoning and evolutionary algorithms" , IEEE Trans. Power Syst., vol. 25, no. 1, Feb. 2010, pp. 565–574.
- [11] Piers, R.J., Adamson, K. Methodologies for Load Forecasting, Intelligent System, 3rd International IEEE Conference, 2006, PP.800-806.
- [12] Sapankevych, N., Sankar, R., "Time series prediction using support vector machines: A survey", IEEE Comput. Intell. Mag., vol. 4, no. 2, 2009, pp. 24–38.
- [13] Setiawan, A., Koprinska, I., Agelidis, V.G., et al. " Very short-term electricity load demand forecasting using support vector regression" ,Proc. Int. Joint Conf. on Neural Networks, 2009, pp. 2888–2894.
- [14] Yun, Z., Quan, Z., Caixin, S., Shaolan, L., Yuming, L., Yang, S., "RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment" ,IEEE Trans. Power Syst., vol. 23, no. 3, Aug. 2008, pp. 853–858.
- [15] Hansen, L., and Salamon, P., "Neural network ensembles", IEEE Trans. Pattern Anal. Mach. Intell., vol. 12, no. 10, 1990, pp. 993–1001.

Short-Term Load Forecasting using an Ensemble of Artificial Neural Networks: Chaharmahal Bakhtiari Case

E.Faraji^{1,2}, M.Mirzaeian³, H.Parvin^{1,2*}, A.Chamkoori¹, Majid Mohammadpour¹

¹Department of Computer Engineering, Khormooj Branch, Islamic Azad University, Khormooj, Iran

²Young Researchers and Elite Club, Nourabad Mamasani Branch, Islamic Azad University, Nourabad Mamasani, Iran
parvin@iust.ac.ir

³Operation and Dispatching Department, Power Distribution Company, Chaharmahal Bakhtiari

Adstract

Short-term load forecasting is very important in electrical marketing. Load forecasting is dependent on climatic condition of every region and the previous structures of electrical consumption in that region; so we have accomplished this through employing climatic data (including temperature and pressure) and real load consumption of Chaharmahal Bakhtiari. We have evaluated our method using four machine learning algorithms: artificial neural networks (multilayer perceptron), ensemble of artificial neural networks, support vector machine and ensemble of support vector machine. Experimental results indicates that ensemble of artificial neural networks is superior to the others in the field of load consumption forecasting of Chaharmahal Bakhtiari.

Keywords: Load Forecasting, Ensemble, Artificial Neural Networks, Support Vector Machine.