استفاده از خوشه‌بندي‌هاي پياپي نقشه خودسازمانده براي بهبود پيش‌بيني پيك بار الكتريكي روزانه مبتني بر شبكه‌هاي عصبي پيشخوراند

عليرضا سروش[۱] و محمدرضا امين‌ناصري*[۲]

[۱] دانشجوي دكتري بخش صنايع - دانشكده فني و مهندسي- دانشگاه تربيت مدرس

[۲] دانشيار بخش صنايع - دانشكده فني و مهندسي - دانشگاه تربيت مدرس

(تاريخ دريافت ۸۶/۴/۱۹ ، تاريخ دريافت روايت اصلاح شده ۸۶/۱۰/۱ ، تاريخ تصويب ۸۶/۱۰/۳۰)

چكيده

اين مقاله يك مدل شبكه عصبي تلفيقي براي پيش‌بيني پيک بار الكتريكي(PLF) روزانه ارائه مي‌كند. از آنجاييكه الگوهاي مشابهي در داده‌هاي پيك بار وجود دارد، خوشه‌بندي داده‌ها دقت پيش‌بيني‌ها را افزايش خواهد داد. اكثر خوشه‌بنديهاي ارائه شده در ادبيات بدون دليل و صرفاً شهودي بوده‌اند. در اين مقاله، ما رويكرد جديدي براي خوشه‌بندي داده‌ها با استفاده از دو نقشه خودسازمانده پياپي ارائه مي‌كنيم. يك شبكه عصبي پيشخوراند(FFNN) براي هر يك از خوشه‌ها جهت پيش‌بينيPLF توسعه داده شده است. جهت ارزيابي اثربخشي مدل تلفيقي پيشنهادي، پيش‌بيني بوسيله توسعه يك شبكه عصبي پيشخوراند كه از داده‌هاي خوشه‌بندي نشده استفاده مي‌كند، انجام شده است. نتايج برتري اثربخشي مدل تلفيقي پيشنهادي را ثابت مي‌كند. همچنين، مدلهاي رگرسيون خطي براي PLF توسعه داده شده است و نتايج نشان مي‌دهد كه مدل تلفيقي پيشنهادي به ميزان قابل‌توجهي، پيش‌بيني‌هاي بهتري را نسبت به مدلهاي رگرسيون خطي تلفيقي توليد مي‌كند. لازم بذكر است كه از داده‌هاي پيك بار شركت برق منطقه‌اي تهران جهت آزمايش و اعتبارسنجي مدل استفاده شده است.

واژه‌های کلیدی: پيش‌بيني - پيك بار الكتريكي روزانه - خوشه‌بندي - نقشه خودسازمانده - شاخص ديويس-بولدين - شبكه عصبي پيشخوراند

مقدمه

صنعت برق از صنايع زيربنائي يك كشور و ركني بسيار مهم در رشد و پيشرفت جوامع امروزي محسوب مي‌شود. بازار تقاضاي جهاني برق با رشد سالانه ۲,٤ درصد، در سال ۲۰۳۰ دو برابر سال ۲۰۰۰ خواهد شد كه اين ميزان رشد بسيار سريعتر از ديگر منابع انرژي است. سهم برق از ميزان كل مصرف انرژي از ۱۸ درصد در سال ۲۰۰۰ به ۲۲ درصد در سال ۲۰۳۰ افزايش مي‌يابد. رشد تقاضاي برق در كشورهاي در حال توسعه در بالاترين حد قرار دارد و با رشد سالانه بيش از ٤ درصد تا سال ۲۰۳۰ به سه برابر مي‌رسد. در نتيجه سهم كشورهاي در حال توسعه از تقاضاي جهاني برق از ۲۷ درصد در سال ۲۰۰۰ به ٤۳ درصد در سال ۲۰۳۰ مي‌رسد. افزايش ميزان انرژي برق در دنيا اهميت اين انرژي را نيز نشان مي‌دهد. از طرف ديگر با تكنولوژي موجود هنوز نميتوان ذخيره اين انرژي را در ابعاد بزرگ امكان پذير نمود؛ بنابراين پيش‌بيني دقيق بار ميتواند نقش مهمي در استفاده اقتصادي از انرژي الكتريكي داشته باشد[۱].

از سالها پيش، پيش‌بيني بار الكتريكي به دليل نقش مهم آن براي انجام عمليات موثر و اقتصادي استفاده از برق مورد توجه دانشگاهيان و محققان قرار گرفته است. احتياجات زندگي مدرن، ما را وادار به استفاده بهينه از قدرت الكتريكي به منظور فعاليت با بيشترين كارايي ممكن مي‌كند كه اين مساله نيازمند انجام پيش‌بيني‌هاي بسيار دقيق است. خطاهاي پيش‌بيني بزرگ ممكن است منجر به ريسك بيش از اندازه يا زمانبندي محافظه‌كارانه بيش از حد شود كه اين موضوع مي‌تواند جريمه‌هاي اقتصادي ناخواسته‌اي را در پي داشته باشد. مقادير پيش‌بيني بالاتر نيز ممكن است، منجر به توليد مقادير زيادي واحدهاي برق شود و در نتيجه ذخاير بالاتر از نياز حقيقي توليد شود، در صورتيكه مقادير پيش‌بيني كمتر ممكن است به ناتواني در ايجاد ذخاير برق قابل قبول منجر شود. در هر دو مورد هزينه عملياتي بالاتري تحميل مي‌شود[۲].

هدف از پيش‌بيني باركوتاه‌مدت، پيش‌بيني تقاضاي الكتريكي آينده مبتني بر داده‌هاي بار و شرايط آب و هوايي است. ايجاد يك متدلوژي پيش‌بيني بار كوتاه‌مدت دقيق و قوي ميتواند موجب برآورد دقيقتر ميزان مصرف الكتريسيته شود[۳]. پيش‌بيني پيك بار الكتريكي روزانه روز بعد،

* نويسنده مسئول : تلفن : ۰۹۱۲۱۰۶۹۷۱۰ , فاكس : ۸۲۸۸۳۳۸۱ , Email: amin_nas@modares.ac.ir

کاربردي اساسي در عمليات و برنامه‌ريزي سيستم قدرت الكتريكي دارد. اين پيش‌بيني، نقشي اساسي در عمليات ورود و خروج نيروگاهي و زمانبندي آن دارد[۴].

ازاينرو، تكنيكهاي پيش‌بيني متنوعي در اين حوزه پيشنهاد شده‌اند. برخي از محققين در مقالات از مدلهاي سري زماني و رگرسيون خطي استفاده نموده‌اند. در اين مدلها رابطه بين متغيرهاي مستقل و متغير وابسته(پيش‌بيني) قابل درك است. ليكن، مدلسازي همبستگي پيچيده بين بار و متغيرهاي ورودي همچون شرايط آب وهوايي و تفاوتهاي بين روزهاي هفته با استفاده از اين تكنيكها مشكل است.

در دو دهه گذشته، تحقيق زيادي برروي كاربرد تكنيكهاي هوش مصنوعي[1](AI) براي مساله پيش‌بيني بار انجام شده است. در ميان اين تكنيكها، مدلهايي كه بيشترين توجه را به سوي خود جلب كرده‌اند، شبكه‌هاي عصبي مصنوعي[2](ANNs) هستند. اولين گزارشها در مورد كاربردشان در مساله پيش‌بيني بار در اواخر دهه ۱۹۸۰ و اوايل دهه ۱۹۹۰ منتشر شده بود. تكنيك شبكه عصبي بخاطر قابليت خوب آن در مدلسازي غيرخطي بطور فراواني در پيش‌بيني بار استفاده شده است[۵].

در اكثر مقالات به چاپ رسيده، شيوه تفكيك داده‌هاي پيك بار هر سال از پيش تعيين شده بوده است، بدين صورت كه بدون ارائه دليل قابل قبولي ايام سال به چند دسته تقسيم شده و پيش‌بيني براي هر دسته انجام شده است. اين مقاله مدل شبكه عصبي پيشخوراند تلفيقي را ارائه مي‌كند كه دو شبكه نقشه خودسازمانده[3] پيايي را براي خوشه‌بندي ايام سال استفاده مي‌كند و سپس پيش‌بيني پيك بار روز بعد توسط شبكه عصبي پيشخوراند[4] مبتني بر روشهاي شبه نيوتني[5] و پس‌انتشار ارتجاعي و لونبرگ-ماركوآرت انجام مي‌شود. همچنين، نتايج پيش‌بيني مدل پيشنهادي با مدل شبكه‌هاي عصبي تلفيقي (بدون لحاظ ساير عوامل آب وهوايي) و مدل رگرسيون خطي تلفيقي و شبكه عصبي پيشخوراند بدون انجام خوشه‌بندي مقايسه مي‌شوند.

دربخشهاي بعدي ابتدا به طور خلاصه به مرور كارهاي انجام شده در اين زمينه خواهيم پرداخت. سپس شبكه‌هاي عصبي نقشه خودسازمانده و نحوه بكارگيري آن را شرح خواهيم داد. در ادامه بااستفاده از شبكه‌هاي عصبي پيشخوراند به پيش‌بيني پيك بار روزانه مي‌پردازيم و در انتها با مقايسه نتايج با ساير مدلها، نتيجه‌گيري خواهيم نمود.

مروری بر مراجع

همان طور كه پيش از اين اشاره شد، براي پيش‌بيني پيك‌بارروزانه مدلهاي مختلفي توسط محققين بكار گرفته شده است؛ برخي از محققين از مدلهاي سري زماني و رگرسيون خطي يا مدلهاي تلفيقي آنها با سيستم خبره استفاده نموده‌اند. امجدي از يك مدل سري زماني استفاده كرده است كه تجربيات اپراتور خبره را نيز بعنوان يكي از پارامترهاي مدل در نظر مي‌گيرد. دو مدل سري زماني براي پيش‌بيني بارهاي ساعتي و پيك بار روزهاي هفته و تعطيلات آخر هفته و عمومي استفاده مي‌شود. از هشت مدل براي بارهاي ساعتي شنبه‌ها، يكشنبه‌ها تا چهارشنبه‌ها، پنجشنبه‌ها و جمعه‌ها بعلاوه تعطيلات عمومي در دو دسته سرد و گرم استفاده مي‌شود. به همين ترتيب هشت مدل نيز براي بارهاي پيك ارائه شده است. همچنين براي پيش‌بيني پيك بار تنها عوامل پيك بار و دماي هوا مورد استفاده قرار مي‌گيرند. در ضمن، ايشان در اين مقاله اشاره مي‌كنند كه اكثر رويكردهاي پيش‌بيني بار متداول هيچ راه‌حلي براي پيش‌بيني پيك بار روزانه ارائه نمي‌كنند[۶].

صادقپور و امين ناصري از تركيب سيستم خبره با رگرسيون خطي چندمتغيره براي پيش‌بيني پيك بار استفاده نموده‌اند[۷]. در اين مدل هر هفته به چهار دسته روزهاي شنبه، يكشنبه تا چهارشنبه، پنجشنبه، جمعه تقسيم شده است. ۱۶ فرمول رگرسيوني براي هر فصل ۴ فرمول براساس تقسيم‌بندي روزها بصورت جداگانه در نظر گرفته شده است. هر رابطه رگرسيوني پارامترهاي مينيمم و ماكزيمم دماي روز موردنظر، پيك بار روز قبل، مينيمم و ماكزيمم درجه حرارت روز قبل، پيك بار روز مشابه در هفته قبل، مينيمم و ماكزيمم درجه حرارت هفته قبل را شامل مي‌شود. براي پيش‌بيني روزهاي تعطيلي خاص نيز برحسب عزا يا جشن، ضريبي خاص در نظر گرفته شده است.

ساعد صياد و جهانگير صياد از مدلي هوشمند براي پيش‌بيني بار روز بعد استفاده نمودند[۸]. مدلي با استفاده از روش رگرسيون چندمتغيره خطي طراحي نمودند. براي تشخيص موارد خاص همچون روزهاي تعطيل از سيستم خبره استفاده شده است.

برخي ديگر، از شبكه نقشه خودسازمانده و تلفيق آن با شبكه پرسپترون براي پيش‌بيني استفاده كرده‌اند. مقدس تفرشي و ياريان با استفاده از تركيب شبكه‌هاي عصبي كوهونن و پرسپترون به پيش‌بيني بار كوتاه‌مدت پرداخته‌اند[۹].

همچنين، براي پيش‌بيني بار روزهاي سال از نه مدل جداگانه استفاده مي‌كند. هفت مدل براي پيش‌بيني بار هر روز هفته، يك مدل براي پيش‌بيني روزهاي تعطيل و يك مدل براي پيش‌بيني روزهاي بعد از تعطيل در نظر گرفته شده است. در اين كار نيز تنها دو عامل بار و دماي هوا لحاظ شده‌اند.

كاريينتيرو و همكارانش يك مدل عصبي متشكل از دو شبكه نقشه خودسازمانده، يكي بالاي ديگري ايجاد كرد[۱۲-۱۰]. آن شبكه‌ها، اطلاعات متني را به صورت كارا رمزي و هدايت مي‌كند. مدل براي پيش‌بيني بار الكتريكي هر ساعت در طول ۲۴ ساعت بعد آموزش داده و ارزيابي شده بود.

سو و چن از يك مدل شبكه عصبي براي پيش‌بيني پيك بار ناحيه‌اي از تايوان استفاده كردند و با تقسيم اين ناحيه به چهار بخش بر خصوصي‌سازي بازار برق تاكيد نمودند، اين شيوه پيش‌بيني موجب تعيين ناحيه پرمصرف‌تر بار مي‌شود[۱۳].

برخي ديگر نيز با شناسايي روزهاي وابسته به روز مورد نظر يا با بررسي عوامل تاثيرگذار ديگر بر مصرف بار به گونه‌اي ديگر از شبكه عصبي براي پيش‌بيني استفاده نمودند. هوانگ و همكارانش يك شبكه عصبي غيرثابت براي پيش‌بيني پيك بار استفاده كردند[۱۴]. به‌منظور پيش‌بيني دقيقتر چندين تكنيك شامل، آناليز گري[۶]، قاعده يادگيري پس‌انتشار تصادفي با نرخ يادگيري پويا و مومنتوم استفاده مي‌شود. پنج شبكه، پيك بار تا پنج روز بعد را محاسبه مي‌كند. در اين تحقيق، از آناليز گري به منظور تعيين روزهايي كه پيك بار آنها تاثيرگذاري بيشتري بر روز هدف دارند، استفاده مي‌شود. در اين تحقيق عدم دسترسي به داده‌هاي رطوبت، سرعت باد، پوشش ابر عنوان شده است.

ايزاكا و همكارانش يك شبكه عصبي ساختاريافته قابل آناليز ارائه نموده‌اند كه مي‌تواند دانش مناسب را استخراج كند و دلايل نتايج پيش‌بيني را با همبستگي مستقل بين متغيرهاي ورودي و پيك بار توضيح دهد[۱۵]. در اين تحقيق، در بهار تنها همبستگي مثبت بين پيك بار هدف و پيك‌بار قبلي ديده مي‌شود و در تابستان تنها همبستگي مثبت بين پيك بار هدف و دما مشاهده مي‌شود.

ساپني و سوني در مقاله‌اي براي پيش‌بيني پيك بار روزانه از شبكه عصبي پيشخوراند همراه با چهار الگوريتم آموزشي پس انتشار شيب مزدوج و الگوريتم سريعترين نزول[۷] استفاده نموده‌اند[۱۶]. همچنين، آنها در مقاله ديگري براي پيش‌بيني پيك بار روزانه از شبكه عصبي پيشخوراند با الگوريتمهاي لونبرگ-ماركوآرت[۸] و شبه‌نيوتني برويدن-فلچر-گلدفارب-شانو[۹] و تقاطع يك مرحله‌اي[۱۰] استفاده نموده‌اند. آنها در اين مقالات علاوه بر بار، عوامل آب و هوايي، مينيمم و ماكزيمم دماي هوا، رطوبت نسبي، سرعت باد، ساعات آفتابي، پوشش ابر، ميزان بارش، فشار بخار آب، دماي خاك در عمق ۵، ۱۰ و ۲۰ سانتيمتر در نظر گرفتند. پيش‌بيني براي يك هفته در هر فصل محاسبه شده است. آنها روزهاي هفته را به چهار دسته روزهاي كاري، روز تعطيل، روز شنبه، روز يكشنبه تقسيم نمودند[۱۷].

براي پيش‌بيني پيك بارهاي ساعتي، كيم و همكارانش يك مدل شبكه عصبي كوهونن را براي دسته‌بندي روزهاي كاري بكار گرفتند[۱۸]. آنها هفته را به چهار خوشه بنامهاي سه‌شنبه تا جمعه، شنبه، يكشنبه و دوشنبه دسته‌بندي نمودند و بارهاي فصلي را با استفاده از تبديل ويولت به سه دسته بهار و پاييز، تابستان و زمستان تقسيم نمودند. نهايتاً، آنها از مدل رگرسيوني مرتبه دوم براي پيش‌بيني پيك بار ساعتي استفاده نمودند. موري و همكارانش از روش ذوب قطعي[۱۱] براي خوشه‌بندي داده‌هاي ورودي استفاده كردند و تنها پيش‌بيني‌ها را براي تابستان (روزهاي كاري جولاي، آگوست، سپتامبر) انجام دادند[۱۹]. ليكن، هيچ آزمايش يا اعتبارسنجي براي ارزيابي عملكرد دسته هاي حاصل شده ارائه نشده بود.

همچنين، مولفين [۲۰] مدلي را براي پيش‌بيني پيك بار روزانه با استفاده از تلفيق يك SOM با FFNN ارائه نمودند كه روزهاي مشابه سال به پنج دسته تقسيم گرديد و تنها از عامل دماي هوا بعنوان يكي از عوامل آب وهوايي اثرگذار بر پيك بار استفاده شد.

تحليل داده‌ها

در اين تحقيق از داده‌هاي پيك بار روزانه چهار سال برق منطقه‌اي تهران از سال ۱۳۷۸ الي ۱۳۸۱ كه معادل ۱۴۶۱ روز است، براي انجام پيش‌بيني پيك بار روزانه استفاده مي‌شود. ساعت پيك بار اين منطقه در نيمه اول سال بين ساعات ۱۹ الي ۲۳ و در نيمه دوم سال بين ساعات ۱۸ الي ۲۲ است. همچنين، براساس همين بازه زماني اطلاعات آب و هوايي مرتبط به زمان پيك بار از ميان اطلاعات سازمان هواشناسي تهران استخراج شده است. اين اطلاعات، دماي هوا، رطوبت، سرعت باد، پوشش ابر را شامل مي‌شـــود. شكل

(١) روند سري زماني روزانه پيك بار منطقه مورد مطـــالعه طي سه سال متوالي نمايش مي‌دهد.

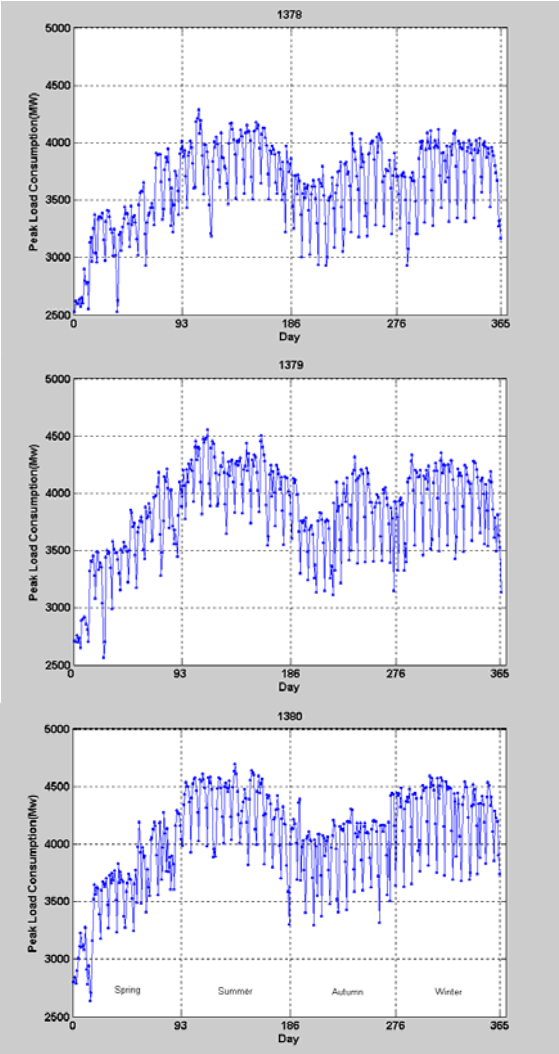

شكل ١: سری زمانی پیک بار الکتریکی روزانه..

همان طور كه در شكل (١) مشاهده مي‌شود مصرف بار روندي روبه افزايش را در هر سال نسبت به همان مقطع زماني در سال قبل نمايش مي‌دهد. با آغاز بهار و شروع ايام تعطيل عيد پيك بار كاهش مي‌يابد، ليكن با نزديك شدن به تابستان هوا گرمتر مي‌شود و مصرف برق بالاتر مي‌رود، با كاهش ميزان گرما پيك بار كاهش مي‌يابد، اما مجدداً با سرد شدن هوا پيك بار افزايش مي‌يابد. اين شيوه تحليل صرفاً نوعي بررسي ديداري است و مي‌تواند داراي خطا باشد، بنابراين لزوم استفاده از ابزاري براي شناسايي و طبقه‌بندي دقيقتر اين الگوهاي مصرف در دسته‌هاي يكسان بيشتر نمايان مي‌شود، زيرا طبقه‌بندي داده‌ها ميتواند موجب كاهش نويز و افزايش در دقت پيش‌بيني پيك بار شود.

تاثير عوامل آب و هوايی بر الگوی مصرف بار

عوامل آب و هوايي كه بر روي مصرف بار كوتاه‌مدت تاثير مي‌گذارند، عبارتند از: درجه حرارت، رطوبت نسبي، سرعت باد و ميزان پوشش ابر. اين عوامل در ذيل توصيف مي‌گردند:

يكي از مهمترين عوامل موثر بر الگوي مصرف ميزان درجه حرارت است. بارهاي خانگي و تجاري در ماههاي گرم سال بدليل استفاده از وسايل سردكننده مانند كولر و فن، .... و در ماههاي سرد سال بدليل استفاده از وسايل گرم‌كننده الكتريكي تحت تاثير درجه حرارت هستند.

همانطور كه در شكل (١) نشان داده شد، ميزان مصرف بار در ايام گرم و سرد تقريباً داراي مقدار يكساني است و تنها استفاده از پيك بار براي خوشه‌بندي ايام سال نمي‌تواند ايام گرم و سرد را از هم تفكيك نمايد و درنتيجه احتمال ايجاد نويز در زمان پيش‌بيني افزايش مي‌نمايد. به اين دليل مي‌توان از پارامتر دما جهت تفكيك مصرف بار ايام گرم و سرد استفاده نمود. رابطه ميان پيك بار و دماي هوا در هر سال تقريباً داراي شكل مشابهي است. شكل (٢) رابطه ميان پيك بار روزانه و دماي هوا را در سال ١٣٨٠ نشان مي‌دهد.

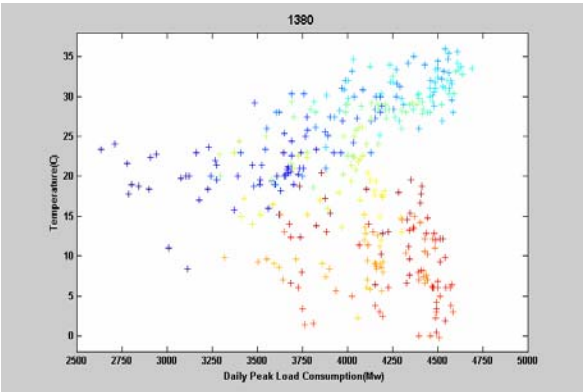

شكل ٢: رابطه بين پيک بار روزانه و دمای هوا در سال ١٣٨٠.

در ايام گرم افزايش رطوبت مي‌تواند موجب افزايش در مصرف بار شود. سرعت باد در ايام گرم مي‌تواند بدليل خنكتر شدن هوا باعث كاهش ميزان مصرف و در ايام سرد منجر به افزايش شدت سرما و ازدياد مصرف شود. ميزان شدت روشنايي هوا باعث تغيير مولفه روشنايي مي‌شود، چون در زمستان در روزهاي ابري هوا ديرتر روشن مي‌شود، لذا چراغها غروبها زودتر روشن مي‌شوند. از اينرو، پوشش ابر موجب وقوع زودتر ساعت پيك بار مي‌شود.

به دليل اينكه در تمامي ايام سال رطوبت، سرعت باد و پوشش ابر عوامل موثري بر پيك بار نيستند و تنها هركدام از آنها در مقطعي از سال بر پيك بار تاثيرگذار هستند، استفاده از اين عوامل نمي‌تواند كمكي براي دستيابي به الگويي مشخص جهت خوشه‌بندي ايام سال بنمايد. به همين دليل اين عوامل تنها در زمان پيش‌بيني مورد استفاده قرار مي‌گيرد.

خوشه‌بندی با شبکه نقشه خودسازمانده

در اكثر تحقيقات انجام شده در زمينه پيش‌بيني بار كوتاه‌مدت وضعيت خوشه‌بندي داده‌ها پيش از انجام پيش‌بيني بدون ارائه دليل قابل قبولي از پيش تعيين شده است[۸-۶] و [۱۷-۱۳]. ليكن، استفاده از خوشه‌بندي مناسب مي‌تواند منجر به كاهش نويز در حين انجام پيش‌بيني شود.

الگوريتم نقشه خودسازمانده (SOM) در سالهاي اخير كاربردهاي فراواني را در زمينه‌هاي علوم مهندسي تا پزشكي، بيولوژي و اقتصاد در ميان محققان پيدا كرده است. تنها ۲۰۹۲ مقاله علمي در طي سالهاي ۱۹۹۸ الي ۲۰۰۲ ارائه شده است كه به نوعي از اين الگوريتم استفاده نموده‌اند[۲۱]. الگوريتم نقشه خودسازمانده ابزار بسيار خوبي جهت خوشه‌بندي داده‌ها مي‌باشد. بطوري كه، براساس آنچه در ادبيات آمده است، ماهيت غيرخطي بودن مصرف پيک بار بر محققين اثبات شده است. SOM نيز مي‌تواند روابط آماري غيرخطي بين داده‌هاي ورودي پيک بار را به روابط هندسي ساده تبديل كند. محاسبات آن يک فرايند رگرسيوني بازگشتي ناپارامتري است كه رگرسيون يک مجموعه مشخص از بردارهاي مدل به فضاي بردارهاي قابل مشاهده در قالب الگوريتمي كه در ادامه آمده است، انجام مي‌شود. آنچنانكه با ارائه هر نمونه، رگرسيون بصورت بازگشتي اجرا مي‌شود. بر اين اساس مي‌توان ادعا نمود كه SOM مي‌تواند اهميت خطاها را لحاظ كند.

دسته‌بندي Q، به معناي افراز مجموعه‌اي از داده‌ها به مجموعه‌اي از دسته‌هاي Q_i، $i=1,...,C$ است. يك تعريف قابل قبول از دسته‌بندي بهينه افرازي است كه فواصل بين نمونه‌هاي داخلي را حداقل كند و فواصل بين دسته‌ها را حداكثر كند.

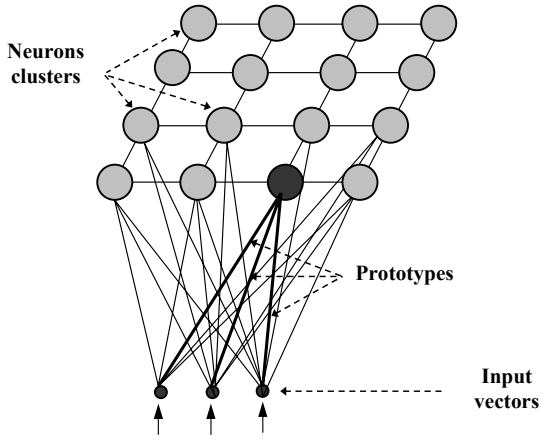

شكل ۳: نقشه خودسازمانده.

معمولاً SOM متشكل از قاعده‌اي دو بعدي، شبكه‌اي از واحدهاي نقشه[۱۲] است. هر واحد i توسط يك بردار پيش‌نمونه $m_i=[m_{i1},...,m_{id}]$ نمايش داده مي‌شود كه d بعد بردار ورودي است. واحدها توسط يك رابطه همسايگي به مجاورت آنها متصل مي‌شوند. تعداد واحدهاي نقشه كه معمولاً از چند تا چندين هزار تغيير مي‌كند، دقت و قابليت تعميم SOM را تعيين مي‌كند. در طول آموزش، SOM يك شبكه فنري تشكيل مي‌دهد كه *توده/نبوه* تشكيل شده از داده‌هاي ورودي را در هم مي‌آميزد. نقاط داده‌اي واقع شده نزديك يكديگر در فضاي ورودي، به صورت واحدهاي نقشه نزديك به هم ترسيم مي‌شوند. بنابراين SOM مي‌تواند همچون يك نقشه توپولوژي از فضاي ورودي به شبكه دو بعدي واحدهاي نقشه تعبير شود. شبكه دو بعدي امكان نمايش و تفسير شكل بي‌نظم و ترتيب خوشه‌بندي‌ها را مي‌دهد[۲۲]. شكل (۳) يك شبكه نقشه خودسازمانده را نمايش مي‌دهد.

الگوريتم SOM

محاسبات SOM يک فرايند رگرسيوني بازگشتي ناپارامتري است كه رگرسيون يک مجموعه مشخص از بردارهاي مدل $m_i \in R^n$ به فضاي بردارهاي قابل مشاهده $x \in R^n$ از طريق فرايند ذيل انجام مي‌دهد:

در هر مرحله آموزش، يك بردار نمونه x به صورت تصادفي از مجموعه داده‌هاي ورودي انتخاب مي‌شود. فواصل بين x و همه بردارهاي پيش‌نمونه محاسبه مي‌شوند. بهترين ميزان تطبيق[۱۳](BMU) كه اينجا بوسيله b مشخص مي‌شود، توسط رابطه (۱) محاسبه مي‌شود:

$$\|x-m_b\|=\min\{\|x-m_i\|\} \quad (1)$$

سپس بردارهاي پيش‌نمونه به‌روز مي‌شوند. BMU و همسايه‌هاي توپولوژيكي آن به نزديكي بردار ورودي در فضاي ورودي حركت داده مي‌شوند. قاعده به‌روزسازي براي بردار پيش نمونه واحد i از طريق رابطه (٢) است:

$$m_i(t+1)=m_i(t)+\alpha(t)h_{bi}(t)(x(t)-m_i(t)), \quad (2)$$

كه t شاخص نمونه مرحله رگرسيوني (زمان) است كه بدينوسيله SOM به صورت بازگشتي آموزش داده مي‌شود، $0<\alpha(t)<1$ عامل نرخ يادگيري (ضريب تطبيق) است كه بصورت يكنواخت با مراحل رگرسيوني (زمان) كاهش مي‌يابد و $h_{bi}(t)$ تابع همسايگي (هسته همسايگي[١٤]) است كه يک تابع كاهشي از فاصله بين مدلهاي i امين و b امين بر روي شبكه نقشه است و بر روي واحد برنده متمركز مي‌شود. تابع همسايگي بصورت رابطه (٣) در نظر گرفته مي‌شود:

$$h_{bi}(t)=\exp(-\frac{\|r_i-r_b\|^2}{2\sigma^2(t)}), \quad (3)$$

كه $r_i\in R^2$ و $r_b\in R^2$ موقعيتهاي نرونهاي b و i بر روي شبكه SOM هستند و $\sigma(t)$ برابر با پهناي تابع همسايگي است كه اين نيز بصورت يكنواخت با مراحل رگرسيوني كاهش مي‌يابد.

قاعده‌اي براي تعيين تعداد دسته‌ها معين نيست و فقط وسانتو و الهونيمي قاعده‌اي از ٢ تا $\sqrt{N}$ را جهت تعيين دامنه تعداد دسته‌ها پيشنهاد نمودند كه N تعداد نمونه‌ها در مجموعه داده‌هاست[٢٢]. الگوريتم SOM استفاده شده در زمان اجرا تابع خطاي رابطه(٤) را مينيمم مي‌كند:

$$E=\sum_{i=1}^{N}\sum_{j=1}^{C}h_{bi}\|x_i-m_j\|^2 \quad (4)$$

كه C تعداد واحدهاي نقشه است. هسته همسايگي $h_{bi}(t)$ در واحد b متمركز مي‌شود كه BMU بردار x_i است و براي واحد j ارزيابي مي‌شود.

با لحاظ رابطه (٤)، SOM براي خطاهاي بزرگ (فواصل بيشتر) جريمه‌هاي بزرگتري را در نظر مي‌گيرد كه اين موضوع بويژه در پيش‌بيني پيک بار كه خطاهاي بزرگ در پيش‌بيني مي‌تواند هزينه‌هاي جبران ناپذيري را در پي داشته باشد، داراي اهميت فراواني است.

در اين مقاله، براي انتخاب بهترين خوشه‌بندي از ميان تقسيم‌بندي‌هاي مختلف از شاخص ديويس- بولدين[١٥] استفاده مي‌شود. اين شاخص هم فاصله درون دسته‌اي و هم فاصله بين دسته‌اي را هنگام ارزيابي خوشه‌بندي حاصل شده مورد ارزيابي قرار مي‌دهد و شاخص مناسبي براي سنجش تقسيم‌بندي نقشه خودسازمانده است، زيرا هر چقدر مقادير كمتر باشند، نشان‌دهنده نتايج خوشه‌بندي خوبي براي دسته‌هاي كروي[١٦] است. براساس شاخص اعتبارسنجي ديويس- بولدين، بهترين خوشه‌بندي رابطه (٥) را مينيمم مي‌كند:

$$\frac{1}{C}\sum_{j=1}^{C}\max_{l\neq j}\left\{\frac{S_c(Q_j)+S_c(Q_l)}{d_{ce}(Q_j,Q_l)}\right\} \quad (5)$$

كه $S_c(Q_j)$ نشاندهنده فاصله درون خوشه‌اي و $d_{ce}(Q_j,Q_l)$ نشاندهنده فاصله بين خوشه‌اي است[٢٢].

نحوه خوشه‌بندی و نرمالسازی داده‌های ورودی

از آنجايي كه مينيمم و ماكزيمم بار در هر سال نسبت به سال قبل در حال افزايش است. به همين دليل بايد داده‌هاي هر سال را به صورت جداگانه با استفاده از نقشه خودسازمانده خوشه‌بندي نمود. زيرا ميزان بار در يك روز از سال نسبت به سال قبل خود بيشتر است، اين موجب مي‌شود كه در هنگام خوشه‌بندي يك روز مشابه در دو سال متفاوت در دسته‌هاي مختلفي قرار گيرند، به همين دليل داده‌هاي سالهاي ١٣٧٨ الي ١٣٨٠ بصورت مجزا براي خوشه‌بندي روزهاي سال آموزش داده شده و اشتراك بين سالها كشف مي‌شود. اين امر موجب مي‌شود كه اطمينان ما به ثبات خوشه‌بندي حاصل شده افزايش يابد و از امكان تعميم آن براي سال ١٣٨١ و سالهاي آتي مطمئن شويم.

همچنين، پس از تعيين محدوده ورودي‌ها مشخص مي‌شود كه پيك بار نسبت به دماي هوا داراي مقادير بزرگتري است، اين مساله باعث مي‌شود كه در زمان خوشه‌بندي عامل دما تاثير چنداني در تقسيم‌بندي نداشته باشد و خوشه‌بندي تنها براساس پيك بار انجام شود. به همين دليل، ورودیها را بايد نرمالسازي نمود. به اين منظور، از نرمالسازي استاندارد با ميانگين صفر و واريانس واحد استفاده مي‌شود. بطوريكه، با استفاده از ميانگين و انحراف معيار داده‌هاي ورودي، رابطه (٦) محاسبه مي‌شود:

$$y_{new}=\frac{y_{old}-mean}{std}, \quad (6)$$

كه y_{old} مقدار اصلي است، y_{new}، مقدار جديد است و $mean$ و std بترتيب ميانگين و انحراف معيار محدوده

داده‌هاي اصلي هستند.

الگوهای آرایه‌ای شبکه و نرم فاصله

داده‌هاي ورودي به SOM از بردارهايي شامل دو عنصر تشكيل شده‌اند كه پيك بار روزانه و دماي هوا در زمان وقوع پيك بار را در برمي‌گيرد. الگوهاي آرايه‌اي مختلفي را مي‌توان براي خوشه‌بندي اين بردارهاي ورودي لحاظ نمود. همانطور كه پيش از اين ذكر شد، قاعده از پيش تعريف شده‌اي براي تعيين تعداد دسته‌ها وجود ندارد. هرچند، در مقاله [۲۲] يک بازه ۲ تا $\sqrt{N}$ را پيشنهاد نمودند كه بر اساس اين قاعده ۲ تا ۱۹ نرون (دسته) مورد آموزش قرار گرفتند كه ۳۷ آرايه مختلف بصورت ذيل را نتيجه مي‌دهد: (۲ ۱)، (۳ ۱)، (۴ ۱)، (۵ ۱)، (۶ ۱)، (۷ ۱)، (۸ ۱)، (۹ ۱)، (۱۰ ۱)، (۱۱ ۱)، (۱۲ ۱)، (۱۳ ۱)، (۱۴ ۱)، (۱۵ ۱)، (۱۶ ۱)، (۱۷ ۱)، (۱۸ ۱)، (۱۹ ۱)، (۱ ۲)، (۲ ۲)، (۳ ۲)، (۴ ۲)، (۵ ۲)، (۶ ۲)، (۷ ۲)، (۸ ۲)، (۹ ۲)، (۱ ۳)، (۲ ۳)، (۳ ۳)، (۴ ۳)، (۵ ۳)، (۶ ۳)، (۱ ۴)، (۲ ۴)، (۳ ۴)، (۴ ۴). لازم به توضيح است كه تعداد نرونها در هر آرايه از ضرب تعداد دسته‌های دو عنصر آرايه در يكديگر حاصل می‌شود. از طرف ديگر، به دليل اينكه ساير آرايه‌ها بهبودي در نتايج حاصل نمي‌كنند، اشاره نشده‌اند. عدد اول داخل پرانتز نمايشگر تعداد نرون براساس مشخصه دماي هوا و عدد دوم تعداد نرون براساس مشخصه دماي هوا است. همچنين، براي سنجش فواصل درون دسته‌اي و بين دسته‌اي از نرم فاصله اقليدسي استفاده مي‌گردد.

آموزش SOM

SOM با استفاده از الگوريتم آموزش افزايشي تصادفي[۱۷] براي تقسيم‌بندي مجموعه داده‌هاي هر سال آموزش داده شده است. در اين الگوريتم در هر دوره آموزشي، همه بردارهاي آموزشي (يا توالي‌ها) هركدام يكبار بصورت تصادفي به شبكه ارائه مي‌شوند و مقادير وزني و بایاس بعد از ارائه هربردار بروز مي‌شوند. آموزش زماني متوقف مي‌شود كه يكي از شرايط ذيل محقق شود: ماكزيمم تعداد دوره‌هاي آموزشي، دستيابي به حداقل خطا، رسيدن به ماكزيمم مقدار زمان.

ابتدا شبكه نرون برنده را شناسايي مي‌كند. سپس وزنهاي نرون برنده و نرونهاي ديگر در همسايگي آن در هر مرحله يادگيري به بردار ورودي نزديكتر مي‌شوند. وزنهاي نرون برنده متناسب با نرخ يادگيري تغيير داده مي‌شوند. وزنهاي نرونهاي در همسايگي آن متناسب با نصف نرخ يادگيري تغيير داده مي‌شوند. نرخ يادگيري و فاصله همسايگي در قالب دو مرحله تغيير داده مي‌شوند: يك مرحله ترتيب و يك مرحله تنظيم. مرحله ترتيب با انجام ۱۰۰۰ گام پايان مي‌پذيرد. درطول اين مرحله، نرخ يادگيري از ۰,۹ آغاز و تا ۰,۰۲ تعديل ميشود و فاصله همسايگي از ماكزيمم فاصله نروني تا ۱ تعديل مي شود. در طول اين مرحله انتظار مي‌رود كه وزنهاي نروني خودشان را در فضاي ورودي سازگار با موقعيت هاي نروني همبسته مرتب كنند. درطول مرحله تنظيم نرخ يادگيري از ۰,۰۲ به كندي كاهش مي‌يابد و فاصله همسايگي هميشه برابر با ۱ است. در طول اين مرحله انتظار مي‌رود وزنها تقريباً بصورت تصادفي در كل فضاي ورودي پراكنده شوند درحاليكه نظم توپولوژيكي‌شان در مرحله ترتيب را حفظ مي‌كنند. به اين ترتيب، نقشه‌هاي ويژگي در حين يادگيري گروه‌بندي ورودي‌شان، توپولوژي و توزيع ورودي‌شان را نيز ياد ميگيرند[۲۳]. همچنين، شبكه‌ها را با ۳۰۰۰ دوره آموزشي آزمون نموده‌ايم.

خروجی خوشه‌بندی

همان طوركه پيش از اين توصيف شد، شبكه عصبي SOM براي ۳۷ آرايه مختلف با استفاده از الگوريتم آموزشي افزايشي تصادفي و در دو مرحله ترتيب و تنظيم آموزش داده شد. نتايج حاصل از آموزش هر يك از آرايه‌ها، مختصات مراكز هريك از نرونها و مكان قرارگيري هر بردار ورودي درون هريك از نرونها را ارائه مي‌كند. سپس، جهت انتخاب بهترين خوشه‌بندي از ميان آرايه‌هاي مختلف، شاخص اعتبارسنجي ديويس- بولدين با استفاده از نرم فاصله اقليدسي محاسبه مي‌گردد. با مقايسه نتايج بدست آمده برای آرایه‌های مختلف بهینه‌ترین حالت خوشه‌بندی مشخص می‌شود. شكل (۴) روند مقادير شاخص ديويس-بولدين برای آرایه‌هایی كه مشخصه پيک بار آنها برابر ۱ و مشخصه دمای هوای آنها از ۲ تا ۱۹ تغيير می‌كند را در سال ۱۳۸۰ نمايش می‌دهد.

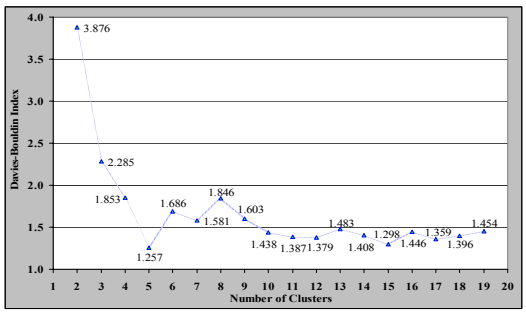

شكل ۴ : مقادير شاخص ديويس-بولدين برای برخی از آرایه‌ها در سال ۱۳۸۰.

جدول ۱ : مقادیر شاخص دیویس-بولدین برای کلیه آرایه‌ها در سال ۱۳۸۰.

تعداد دسته مشخصه دمای هوا	مقادیر شاخص دیویس-بولدین			
	آرایه (تعداد دسته ۱)	آرایه (تعداد دسته ۲)	آرایه (تعداد دسته ۳)	آرایه (تعداد دسته ۴)
۱		۳,۸۷۶	۲,۲۸۵	۱,۸۵۳
۲	۳,۸۷۶	۳,۹۳۷	۲,۶۸۳	۲,۶۰۳
۳	۲,۲۸۵	۱,۳۱۱	۱,۴۶۳	۱,۳۶۱
۴	۱,۸۵۳	۱,۸۹۲	۱,۷۰۸	۱,۴۲۹
۵	۱,۲۵۷	۱,۵۷۱	۱,۳۳۵	
۶	۱,۶۸۶	۱,۶۴۸	۱,۳۸۱	
۷	۱,۵۸۱	۱,۸۵۵		
۸	۱,۸۴۶	۲,۱۸۱		
۹	۱,۶۰۳	۱,۶۸۹		
۱۰	۱,۴۳۸			
۱۱	۱,۳۸۷			
۱۲	۱,۳۷۹			
۱۳	۱,۴۸۳			
۱۴	۱,۴۰۸			
۱۵	۱,۲۹۸			
۱۶	۱,۴۴۶			
۱۷	۱,۳۵۹			
۱۸	۱,۳۹۶			
۱۹	۱,۴۵۴			

همان طور که در شکل (۴) مشاهده می‌شود، کمترین مقدار شاخص دیویس-بولدین از میان آرایه‌های مختلف اجرا شده برای آرایه (۵ ۱) با مقدار ۱,۲۵۷ حاصل می‌شود. همچنین، محاسبات شاخص دیویس-بولدین برای سایر آرایه‌های نامبرده نیز انجام شد، لیکن بهبودی در نتیجه حاصل نگردید. جدول (۱) مقادیر شاخص دیویس-بولدین براي كليه آرايه‌ها در سال ۱۳۸۰ را نشان مي‌دهد.

با این اوصاف، بردارهای ورودی سال ۱۳۸۰ به پنج نرون (دسته) تقسیم می‌شوند. بدین معني كه داده‌ها در بهترين حالت برحسب پيک بار به يک دسته و برحسب دماي هوا به پنج دسته تقسيم مي‌شوند. لازم بذكر است كه پس از تكرار الگوريتم در مورد سالهای ۱۳۷۸ و ۱۳۷۹ نیز کمترین مقدار شاخص دیویس-بولدین با پنج نرون بدست می‌آید. به این ترتیب که برای پنج نرون در سال ۱۳۷۸، مقداری برابر با ۱,۰۷۷ و در سال ۱۳۷۹ مقداری برابر با ۱,۰۳۸ حاصل می‌شود. از این رو، این تعداد خوشه برای سال ۱۳۸۱ نیز تعمیم داده می‌شود.

جدول ۲: خروجی و نتایج خوشه‌بندی نهایی.

نرون	هفته‌هاي سال
نرون ۱	دسته سوم شنبه‌ها تا چهارشنبه‌ها(هفته آخر خرداد، تیر، مرداد، شهریور، هفته اول مهر)، دسته سوم پنجشنبه‌ها(تیر، مرداد، سه هفته اول شهریور)
نرون ۲	دسته دوم شنبه‌ها تا چهارشنبه‌ها(هفته آخر اردیبهشت، سه هفته اول خرداد، سه هفته آخر مهر، دو هفته اول آبان)، دسته دوم پنجشنبه‌ها(خرداد، هفته آخر شهریور، هفته اول مهر)، دسته دوم جمعه‌ها و ایام تعطیل (سه هفته آخر خرداد، تیر، مرداد، شهریور، هفته اول مهر)
نرون ۳	ایام عید، دسته اول شنبه‌ها تا چهارشنبه‌ها(فروردین، سه هفته اول اردیبهشت)، دسته اول پنجشنبه‌ها(فروردین، اردیبهشت، سه هفته آخر مهر، دو هفته اول آبان)، دسته اول جمعه‌ها و ایام تعطیل(فروردین، اردیبهشت، هفته اول خرداد، سه هفته آخر مهر، دو هفته اول آبان، هفته آخر اسفند)
نرون ۴	دسته سوم جمعه‌ها و ایام تعطیل(دو هفته آخر آبان، آذر، دي، بهمن، سه هفته اول اسفند)
نرون ۵	دسته چهارم شنبه‌ها تا چهارشنبه‌ها(دو هفته آخر آبان، آذر، دي، بهمن، اسفند)، دسته چهارم پنجشنبه‌ها(دو هفته آخر آبان، آذر، دي، بهمن، اسفند)

به اين ترتيب، بهترين خوشه‌بندي براي تفكيك هفته‌هاي يكسال با توجه به شرايط آب و هوايي مشابه مقاطع مختلف سال براساس دو عامل دماي هوا و پيك بار انجام مي‌شود. ليكن، براي تفكيك ايامي از سال كه داراي دماي هواي تقريباً مشابه و اختلاف پيك بار محسوسي هستند، نياز به استفاده از شبكه نقشه خودسازمانده ديگري است تا هر يك از پنج نرون حاصل از نقشه خودسازمانده اوليه را براساس عامل پيك بار تقسيم‌بندي بنمايد. به اين ترتيب، علاوه بر كاهش نويز حاصل از اختلاف دماي هوا، نويز حاصل از اختلاف پيك بار نيز كاهش مي‌يابد. به اين ترتيب كه نرون (دسته) يك به دو دسته، نرون دو به سه دسته، نرون سه به چهار، نرون چهار به همان يك دسته و نرون پنج به دو دسته تقسيم مي‌شود. پس از انجام خوشه‌بندي هر يك از نرونها، ۱۲ دسته براي انجام پيش‌بيني حاصل مي‌شود. جدول (۲)، خروجي و نتيجه خوشه‌بندي نهايي ايام سال نمايش مي‌دهد. لازم بذكر است كه استفاده از شبكه عصبي SOM موجب كاهش خطاي پيش‌بيني از طريق طبقه‌بندي بهينه داده‌هاي ورودي نزديك به يكديگر در يك دسته مي‌شود.

پیش‌بینی با شبکه عصبی پیشخوراند

پس از انجام خوشه‌بندي، در اين مرحله به پيش‌بيني پيك بار روز بعد خواهيم پرداخت. پيش‌بيني با استفاده از شبكه عصبي پيشخوراند(FFNN) صورت مي‌گيرد. FFNN بعنوان يك تخمين‌زننده غيرخطي كاملاً معروف است. پاسخ يك نرون در لايه خروجي بعنوان تابعي از ورودیهاي آن به صورت زير است:

$$a^2 = f^2(W^2 f^1(W^1 p + b^1) + b^2) \qquad (۷)$$

كه f^2 و f^1 ميتوانند توابع فعالسازي سيگموید، خطي يا آستانه‌اي باشند. p ، ورودیهاي به شبكه، W^2 و W^1، وزنها، b^2 و b^1، بایاسهاي شبكه هستند.

همچنين، داده‌هاي سه سال براي آموزش مدل و داده‌هاي يك سال جهت پيش‌بيني و اعتبارسنجي مدل مورد استفاده قرار مي‌گيرد. در اينجا لازم به توضيح است كه براي بهبود نتايج پيش‌بيني هر يک از خوشه‌ها، بهتر است شبكه عصبي پيشخوراند را هر ساله با افزودن مقادير پيک بار روزانه سال جديد آموزش داد تا شبكه عصبي بتواند براساس شرايط بروزتر پيش‌بيني‌هاي دقيقتري را ارائه نمايد. در ادامه به معرفي مشخصات شبكه مورد استفاده براي پيش‌بيني مي‌پردازيم.

داده‌های ورودی

عوامـــل تاثيرگذار بر پيك بار در حالتهاي مختلف يك وقفـــه[۱۸] و دو وقفه در دسته‌هاي پنجشنبه‌ها، جمعه‌ها و ايام تعطيل و حالتهاي يك وقفه، دو وقفه و پنج وقفه در دسته‌هاي شنبه‌ها تا چهارشنبه‌ها مورد بررسي و آزمايش قرار گرفتند. در نهايت بهترين نتايج در هر دسته با داده‌هاي ورودي زير بدست آمده‌اند:

دسته ايام عيد: روز ماه، شماره سال، دماي هوا و سرعت باد و پوشش ابر همان روز، پيك بار و دماي هوا و سرعت باد و پوشش ابر روز مشابه قبلي.

دسته اول جمعه‌ها و ايام تعطيل: شماره ماه، شماره سال، دماي هوا، رطوبت، پوشش ابر همان روز، پيك بار و دماي هوا، رطوبت، پوشش ابر هفته قبل و دو هفته قبل.

دسته دوم جمعه‌ها و ايام تعطيل: شماره ماه، شماره سال، دماي هوا و سرعت باد و رطوبت همان روز، پيك بار و دماي هوا و سرعت باد و رطوبت هفته قبل و دو هفته قبل.

دسته سوم جمعه‌ها و ايام تعطيل: شماره ماه، شماره سال، دماي هوا و پوشش ابر همان روز، پيك بار و دماي هوا و پوشش ابر هفته قبل.

دسته اول پنجشنبه‌ها: شماره ماه، شماره سال، دماي هوا و پوشش ابر همان روز، پيك‌بار و دماي هوا و پوشش ابر هفته قبل و دو هفته قبل.

دسته دوم پنجشنبه‌ها: شماره ماه، شماره سال، دماي هوا، رطوبت و سرعت باد همان روز، پيك بار و دماي هوا و رطوبت و سرعت باد هفته قبل.

دسته سوم پنجشنبه‌ها: شماره ماه، شماره سال، دماي هوا و سرعت باد و رطوبت همان روز، پيك بار و دماي هوا و سرعت باد و رطوبت هفته قبل.

دسته چهارم پنجشنبه‌ها: شماره ماه، شماره سال، دماي هوا و پوشش ابر همان روز، پيك بار و دماي هوا و پوشش ابر هفته قبل.

دسته اول شنبه‌ها تا چهارشنبه‌ها: شماره ماه، شماره سال، دماي هوا و پوشش ابر همان روز، پيك بار و دماي هوا و پوشش ابر آخرين شنبه تا چهارشنبه (غيرتعطيل) پيش از اين روز.

دسته دوم شنبه‌ها تا چهارشنبه‌ها: شماره ماه، شماره سال، دماي هوا و سرعت باد همان روز، پيك بار و دماي هوا و سرعت باد روز قبل(غيرتعطيل) و هفته قبل.

دسته سوم شنبه‌ها تا چهارشنبه‌ها: شماره ماه، شماره سال، دماي هوا و سرعت باد همان روز، پيك بار و دماي هوا و سرعت باد روز قبل و هفته قبل.

دسته چهارم شنبه‌ها تا چهارشنبه‌ها: شماره ماه، شماره سال، دماي هوا و پوشش ابر همان روز، پيك بار و دماي هوا و پوشش ابر روز قبل، دو روز قبل(غير تعطيل) و هفته قبل.

پیش‌پردازش داده‌ها

اگر مراحل پيش‌پردازش معيني بر روي ورودي‌ها و هدفهاي كمي شبكه انجام شود، آموزش شبكه عصبي كاراتر انجام مي‌شود. از اينرو، پيش از آموزش هم مقياس‌سازي ورودي‌ها و هدفها انجام مي‌شود. پيش‌پردازش داده‌ها سبب مي‌شود داده‌ها در دامنه معيني فشرده شوند. زمانيكه از توابع سيگموید براي لايه‌هاي پنهان شبكه استفاده مي‌شود، اين فشرده‌سازي مي‌تواند نتايج شبكه را بهبود بخشد.

در اين تحقيق نيز، به دليل اينكه مقياس داده‌هاي پيك بار، دماي هوا، رطوبت، سرعت باد، پوشش ابر متفاوت است، استفاده از نرمالسازي ضروري بنظر مي‌رسد. از اينرو، نرمالسازي داده‌هاي هر دسته با استفاده از روش نرمالسازي استاندارد با ميانگين صفر و واريانس واحد انجام مي‌شود.

برخي مواقع، ابعاد بردار ورودي بزرگ است اما مولفه‌هاي بردارهاي ورودي بشدت همبستگي دارند. كاهش ابعاد بردارهاي ورودي در اين شرايط مفيد است. آناليز مولفه اصلي[19] (PCA) ابزاري كارا براي انجام اين عمل است[۲۳].

از اينرو، بردارهاي ورودي نرمال شده با ميانگين صفر و واحد مورد آناليز مولفه اصلي قرار مي‌گيرند. از آناليز مولفه اصلي جهت كاهش ابعاد بردارهاي ورودي و كاهش پيچيدگي مساله در هريك از دسته‌ها و حذف عواملي كه تاثيرگذاري كمتري بر روي متغير خروجي دارند، استفاده مي‌كنيم. PCA، مولفه‌هاي اصلي را حذف مي‌كند كه كمتر از ۱% در كل تغييرات مجموعه داده‌ها اثرگذاري دارند. اين آناليز زمان آموزش كمتر، معماري ساده‌تر، آموزش با داده‌هاي مشابه و پيش‌بيني بهتر را در پي خواهد داشت[۱۷-۱۶].

PCA، يک روش آماری برای تعريف متغيرهاي جديد برحسب تركيب خطی از متغيرهای اوليه است. متغيرهای جديد نسبت به هم مستقل بوده و واريانس آنها دارای روند نزولی است. هدف از آناليز مؤلفه اصلی، استخراج مؤلفه‌های اصلی مجموعه‌اي از متغيرهای اوليه بوده كه اولين مؤلفه استخراجی دارای بيشترين واريانس مجموعه اوليه داده‌ها بوده و مؤلفه‌های استخراجی بعدی واريانس كمتری از مجموعه اوليه داده‌ها را لحاظ كرده و مجموع واريانس مؤلفه‌های استخراجی مساوی واريانس كل داده‌ها است. همچنين، مؤلفه‌های استخراج شده نسبت به هم مستقل هستند. به طور كلی در روش آناليز مؤلفه اصلی از p متغير اوليه می‌توان m مولفه اصلي مستقل $(m < p)$ استخراج نمود. از طريق مؤلفه‌های استخراجی فضاي p بعدي اطلاعات به فضاي m بعدی قابل كاهش است. از نظر رياضي مولفه‌هاي اصلي p متغير اوليه بصورت ذيل قابل نمايش است[۲۴]:

$$\xi_1 = w_{11}z_1 + w_{12}z_2 + \ldots + w_{1p}z_p$$
$$\xi_2 = w_{21}z_1 + w_{22}z_2 + \ldots + w_{2p}z_p$$
$$\xi_p = w_{p1}z_1 + w_{p2}z_2 + \ldots + w_{pp}z_p$$

در روابط بالا $\xi_1, \xi_2, \ldots, \xi_p$، p مولفه اصلي و w_{kz} ضريب z امين متغير در k امين مولفه است. هدف از آناليز مولفه‌هاي اصلي تخمين ضرايب w_{kz} با توجه به موارد زير است.

- اولين مولفه حداكثر واريانس داده‌ها را لحاظ كرده و دومين مولفه حداكثر واريانس لحاظ نشده توسط اولين مولفه را لحاظ نموده و الي آخر.
- $w_{k1}^2 + w_{k2}^2 + \ldots + w_{kp}^2 = 1$
  $k = 1,2,\ldots, p$
- $w_{k1}w_{z1} + w_{k2}w_{z2} + \ldots + w_{kp}w_{zp} = 0$
  براي همه $i \neq j$

بدين ترتيب، پس از استفاده از PCA جهت كاهش بردارهاي ورودي به هر دسته، تغييري در دسته ۱ ايجاد نشده و تعداد ۹ بردار ورودي ثابت مي‌ماند. ليكن تعداد بردارهاي ورودي دسته‌هاي ۲ و ۳ از ۱۳ بردار به ۱۱ بردار، بردارهاي ورودي دسته ۴ از ۷ بردار به ۶ بردار، بردارهاي ورودي دسته ۵ از ۱۰ بردار به ۸ بردار، بردارهاي ورودي دسته‌هاي ۶ و ۷ از ۹ بردار به ۸ بردار تقليل مي‌يابد، در دسته ۸ نيز ۷ بردار ورودي ثابت مي‌ماند، بردارهاي ورودي دسته ۹ از ۱۹ بردار به ۱۵ بردار، بردارهاي ورودي دسته ۱۰ و ۱۱ از ۱۰ بردار به ۸ بردار و بردارهاي ورودي دسته ۱۲ از ۱۳ بردار به ۱۰ بردار كاهش مي‌يابد. شكل (۵) ماتريس مولفه‌هاي دوران داده شده[20] متغيرهاي ورودي به دسته ۱۲ را بعنوان نمونه نشان مي‌دهد.

ماتريس مولفه‌هاي دوران داده شده										
متغيرهاي اصلي	مولفه									
	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
شماره ماه	۰,۱	۰	-۰,۱	**۱**	۰	۰	۰	۰	۰	۰
شماره سال	**۱**	۰	۰,۱	-۰,۱	۰	۰	۰	۰	۰	۰
دماي همانروز	-۰,۱	**۰,۹**	۰,۱	۰	۰	-۰,۱	-۰,۱	۰	-۰,۳	۰,۲
پوشش ابر همانروز	۰	۰,۱	۰,۱	۰	۰,۱	**۱**	۰	۰	۰	۰
پيک بار روز قبل	**۰,۹**	-۰,۱	-۰,۱	۰	۰	۰	۰	۰	-۰,۱	-۰,۲
دماي روز قبل	-۰,۱	**۰,۹**	۰,۱	۰	۰	۰,۱	۰	۰	۰,۱	-۰,۲
پوشش ابر روز قبل	۰	۰	۰,۱	۰	**۱**	۰,۱	۰	۰	۰	۰
پيک بار دو روز قبل	**۰,۹**	-۰,۱	-۰,۱	۰,۱	۰	۰	۰	۰	-۰,۱	۰
دماي دو روز قبل	-۰,۱	**۰,۸**	۰,۳	۰	۰,۱	۰,۱	۰	۰	۰,۵	۰
پوشش ابر دو روز قبل	۰	۰	۰	۰	۰	۰	**۱**	۰	۰	۰
پيک بار هفته قبل	**۰,۹**	۰	-۰,۱	۰,۲	۰	۰	۰	۰	۰,۱	۰,۲
دماي هفته قبل	-۰,۱	۰,۳	**۰,۹**	-۰,۱	۰,۱	۰,۱	۰	۰	۰	۰
پوشش ابر هفته قبل	۰,۱	۰	۰	۰	۰	۰	۰	**۱**	۰	۰

شكل ۵ : ماتريس مولفه‌هاي دوران داده شده براي دسته ۱۲.

همان طور که در شکل (۵) مشاهده مي‌کنيد ۱۰ متغير جديد براي کليه داده‌ها حاصل مي‌شود که اين ۱۰ متغير تقريباً ۹۷,۹ درصد کل واريانس مجموعه داده‌ها را محاسبه مي‌کنند. بطوري که متغيرهاي اصلي شماره سال، پيک بار روز قبل، پيک بار دو روز قبل، پيک بار هفته قبل در شکل‌گيري مولفه اول، متغيرهاي اصلي دماي همانروز، دماي روز قبل، دماي دو روز قبل در شکل‌گيري مولفه دوم، متغير اصلي دماي هفته قبل در شکل‌گيري مولفه سوم، متغير اصلي شماره ماه در شکل‌گيري مولفه چهارم، متغير اصلي پوشش ابر روز قبل در شکل‌گيري مولفه پنجم، متغير اصلي پوشش ابر همانروز در شکل‌گيري مولفه ششم، متغير اصلي پوشش ابر دو روز قبل در شکل‌گيري مولفه هفتم و متغير اصلي پوشش ابر هفته قبل در شکل‌گيري مولفه هشتم تاثيرگذاري بيشتري دارند. مولفه‌هاي نهم و دهم درصد کمتري از کل واريانس را محاسبه مي‌کنند. اما با توجه به اينکه بيش از ۱% در کل تغييرات مجموعه داده‌ها اثرگذاري دارند، لحاظ مي‌شوند. همچنين مقدار کلي ۰,۷۴۰ براي سنجه کفايت نمونه‌گيري کايسر-مير-اولکين[۲۱] (KMO) نشان مي‌دهد که ماتريس همبستگي براي فاکتورگيري نسبتاً مناسب است[۲۴]. به همين ترتيب، با استفاده از ابزار PCA، ماتريس مولفه‌هاي دوران داده شده براي ساير دسته‌ها نيز محاسبه شده و ابعاد متغيرهاي ورودي به شبکه کمتر خواهد شد.

تعداد لايه‌ها، نرونها و توابع تبديل

توابع تبديل گوناگوني براي استفاده در لايه‌هاي مختلف يك شبکه وجود دارد. با توجه به نوع مساله و کاربرد مورد نظر هريك از توابع در جايي مورد استفاده قرار مي‌گيرند. استفاده از توابع تبديل سيگموید و تانژانت هيپربوليك در لايه پنهان، سبب تثبيت خروجي نرونهاي اين لايه در بين محدوده‌هاي معين [۰،۱] و [۱،۱-] مي‌شود و در نتيجه با جلوگيري از توليد مقادير بسيار بزرگ که باعث از کار افتادن شبکه مي‌شود، از شکست فرايند آموزش جلوگيري خواهد شد.

در اين تحقيق از شبکه‌اي دو لايه استفاده مي‌شود که شامل يك لايه مخفي است، تعداد نرونها در لايه مخفي بسته به تعداد متغيرهاي ورودي و تعداد الگوهاي آموزشي از ۱ تا ۵۰ گره آزمايش شده است و نتايج نشان داد که بهترين تعداد نرون براي خوشه ۱ برابر ۳۰، براي خوشه ۲ برابر ۳۱، براي خوشه ۳ برابر ۲۴، براي خوشه ۴ برابر ۲۰، براي خوشه ۵ برابر ۴۲، براي خوشه ۶ برابر ۴۸، براي خوشه ۷ برابر ۴۲، براي خوشه ۸ برابر ۲۳، براي خوشه ۹ برابر ۱۷، براي خوشه ۱۰ برابر ۵۰، براي خوشه ۱۱ برابر ۴۵ و براي خوشه ۱۲ برابر ۱۱ است. در لايه خروجي نيز يك نرون وجود دارد که پيش‌بيني پيك بار روز بعد را با توجه به ورودي‌هاي موردنياز هر دسته به ما ارائه مي‌کند.

همچنين، در لايه مخفي به دليل مثبت بودن خروجي‌ها از تابع تبديل لجيستيك سيگموید استفاده مي‌شود و به سبب عدم وجود محدوديت در مقدار خروجي‌ها از تابع تبديل خطي در لايه خروجي استفاده مي‌شود.

الگوريتمهای آموزش شبکه

قاعده يادگيري در شبکه عصبي، جهت ياد دادن کاري خاص به شبکه استفاده مي‌شود. براي اين کار از رويه‌اي که وزنها و بایاسهاي شبکه را اصلاح مي‌نمايد، استفاده مي‌شود که الگوريتم آموزش ناميده مي‌شود. در اين تحقيق دو الگوريتم شبه نيوتني شامل تقاطع يك مرحله‌اي (OSS) و برويدن-فلچر-گلدفارب-شانو(BFGS) و الگوريتمهاي لونبرگ-ماركوآرت(LM) و پس‌انتشار ارتجاعي(RP) در طراحي مدل مورد بررسي قرار گرفته‌اند[۲۵].

- الگوريتم پس انتشار خطای ارتجاعی

شبکه‌هاي چند لايه، عموماً از توابع سيگموئيد، در لايه‌هاي پنهان خود استفاده مي‌کنند. بطوريکه، هر چقدر ورودي‌ها بزرگتر مي‌شوند، شيب تابع به سمت صفر ميل مي‌نمايد. اين مسئله زمان آموزش يك شبکة چندلايه با توابع سيگموئيد که از الگوريتم‌هاي نزول شيب براي آموزش استفاده مي‌کند، باعث بروز مشکل مي‌شود. زيرا شيب مي‌تواند يك مقدار بسيار کوچك اختيار کند و بنابراين حتماً در شرايطي که مقادير از مقدارهاي بهينة خود فاصلة زيادي دارند، باعث تغييرات کوچك در وزن‌ها و بایاس‌ها مي‌شود. مقصود الگوريتم پس انتشار ارتجاعي، حذف اين تأثيرات مضر، از بزرگي اين مشتقات جزيي است. ميزان تغيير وزن‌ها بوسيلة دو مقدار مجزا که توسط کاربر براي افزايش و کاهش وزن‌ها تعيين مي‌شود، صورت مي‌گيرد. در صورت صفر بودن مشتق، مقدار اصلاح بدون تغيير باقي مي‌ماند. هرگاه وزن‌ها نوسان کنند، تغيير وزن کاهش خواهد يافت و اگر وزن‌ها تغيير در يك جهت را در تکرارهاي مختلف ادامه دهند،

اندازة تغيير افزايش داده خواهد شد. عملكرد اين الگوريتم زياد به تنظيم پارامترهاي آموزش حساس نيست[۲۵].

- الگوريتم برويدن-فلچر-گلدفارب- شانو(BFGS)

روش‌هاي نيوتني، يكي از انتخاب‌هاي پيش‌رو براي روش‌هاي شيب مزدوج است كه جهت بهينه‌سازي سريع‌تر بكار مي‌رود. قدم اصلي در روش‌هاي نيوتني عبارتست از محاسبة $X_{k+1}=X_k-A_k^{-1}.g_k$ كه در آن A_k ماتريس هسين (مشتق دوم) شاخص عملكرد مقادير وزن و بايا‌س فعلي است. روش نيوتن اغلب سريع‌تر از روش‌هاي شيب مزدوج ديگر همگرا مي‌شود. ولي متأسفانه محاسبة ماتريس هسين، براي شبكه‌هاي عصبي پيشخوراند بسيار پيچيده است.

طبقه‌اي از الگوريتم‌ها كه مبتني بر روش نيوتن هستند ولي نيازي به محاسبة مشتق دوم ندارند، بنام الگوريتم‌هاي «شبه نيوتني(سكانت)» بوجود آمده‌اند. اين الگوريتم‌ها، يك ماتريس هسين تخميني را در هر تكرار الگوريتم، محاسبه مي‌كنند. اصلاح لازم بعنوان تابعي از شيب محاسبه مي‌شود. روش‌هاي شبه نيوتني كه در مطالعات انتشار يافته، غالباً موفق ارزيابي شده‌اند عبارتند از: بريدن، فلچر، گلدفارب و شانو.

كلية اين روش‌ها در يك الگوريتم با نام BFGS بكار گرفته شده‌اند. اين الگوريتم در هر تكرار، محاسبات بيشتري انجام مي‌دهد ولي عموماً در تكرارهاي كمتري همگرا مي‌شود. ابعاد ماتريس هسين n^2*n^2 است كه n تعداد وزن‌ها و بايا‌س‌هاي شبكه است. بنابراين براي شبكه‌هاي بسيار بزرگ ممكن است، بهتر باشد از الگوريتم پس‌انتشار ارتجاعي يا الگوريتم‌هاي شيب مزدوج استفاده شود. اما براي شبكه‌هاي كوچكتر اين الگوريتم كاراتر است[۲۵].

- الگوريتم شبه نيوتني تقاطع يک مرحله‌اي

از آنجا كه الگوريتم برويدن- فلچر- گلدفارب- شانو نسبت به الگوريتم‌هاي شيب مزدوج، به فضاي ذخيره و محاسبات زيادي در هر بار تكرار نيازمند است، يك تقريب تقاطعي با محاسبات و حجم ذخيرة كمتر لازم است. روش «تقاطع يك مرحله‌اي» تلاشي است در جهت ايجاد يك پل بر روي شكاف بين الگوريتم‌هاي شيب مزدوج و الگوريتم‌هاي شبه نيوتني. اين الگوريتم، ماتريس هسين را به شكل كامل ذخيره نمي‌كند، بلكه فرض مي‌كند در هر تكرار، هسين قبلي، ماتريس همان‌ي است. مزيت بزرگ اين فرض اين است كه مسير جستجوي جديد مي‌تواند بدون محاسبة معكوس ماتريس محاسبه شود[۲۵].

- الگوريتم لونبرگ- ماركوآرت

الگوريتم لونبرگ-ماركوآرت، شبيه الگوريتم‌هاي شبه نيوتني براي بهبود سرعت آموزش، بدون نياز به محاسبه ماتريس هسين، طراحي شده است. زمانيكه تابع عملكرد به شكل مجموع مربعات خطا است، ماتريس هسين مي‌تواند بصورت $H=J^T*J$ تقريب زده شود و شيب به صورت $g=J^T*e$ محاسبه شود. در اين رابطه J ماتريس ژاكوبين است كه مشتقات اول خطاهاي شبكه را نسبت به وزن‌ها و بايا‌س‌ها شامل مي‌شود و e برداري از خطاهاي شبكه است. ماتريس ژاكوبين مي‌تواند از طريق يك تكنيك پس‌انتشار استاندارد كه كمي پيچيده‌تر از محاسبه ماتريس هسين است، محاسبه شود. الگوريتم لونبرگ- ماركوآرت از يك تقريب زني ماتريس هسين استفاده مي‌كند كه به روش نيوتن شباهت دارد.

$$X_{k+1}=X_k-[J^T.J+\mu I]^{-1}.J^T.e \qquad (۶)$$

زماني كه μ صفر باشد دقيقاً رابطة مورد استفاده در روش نيوتن حاصل مي‌شود و زمانيكه بزرگ باشد، الگوريتم نزول شيب با اندازه قدم‌هاي كوچك حاصل مي‌شود. روش نيوتن در نزديك يك خطاي كمينه، سريع‌تر و دقيق‌تر است. بنابراين هدف انتقال به سمت الگوريتم نيوتن با سرعت هر چه بيشتر است. بنابراين μ بعد از هر قدم موفقيت‌آميز (كاهش در تابع عملكرد) كاهش مي‌يابد و تنها زماني افزايش مي‌يابد كه يك قدم آزمايشي تابع عملكرد را افزايش دهد. در اين روش تابع عملكرد، معمولاً در هر تكرار الگوريتم كاهش خواهد يافت. اين الگوريتم به عنوان سريع‌ترين روش براي آموزش شبكه‌هاي پيشخوراند متوسط مطرح است[۲۵].

نتايج نشان داد كه هر يک از اين الگوريتم‌ها در تعدادي از دسته‌ها با توجه به تعداد ورودي‌ها و شرايط آن دسته پيش‌بيني‌هاي دقيق تري را ارائه مي‌كنند. بطوريكه، الگوريتم RP در خوشه‌هاي ۱، ۲، ۶، ۷، ۱۰ و ۱۱، الگوريتم OSS در خوشه ۳، ۴، ۵ و ۹ و الگوريتم LM در خوشه‌هاي ۸ و ۱۲ نتايج بهتري را ارائه مي‌كنند. همچنين، الگوريتم BFGS در هيچيک از خوشه‌ها نسبت به سه الگوريتم ديگر پيش‌بيني بهتري را نشان نمي‌دهد.

معيار عملكرد

براي سنجش خطاي پيش‌بيني بايد از معيار عملكردي مناسب كه به خوبي نتايج پيش‌بيني را مورد بررسي قرار دهد استفاده نمود. در اكثر مقالات، براي سنجش خطاي پيش‌بيني از ميانگين درصد قدرمطلق خطا[۲۲](MAPE) استفاده شده است؛ MAPE، يک استاندارد در صنعت تامين الكتريسيته است. انتخاب معيارهاي خطا براي كمك به مقايسه مدلهاي پيش‌بيني بسيار مورد بحث قرار گرفته است، اكثر مولفين توافق كرده‌اند كه تابع جريمه همبسته با خطاهاي پيش‌بيني بايد در ارزيابي يك مدل استفاده شود. اگر تابع جريمه خطي باشد(خطي در درصد نه در قدرمطلق خطا)، MAPE، معياری كافي خواهد بود؛ ليكن، مطالعات اخير و تجربه اپراتورهاي سيستم نشان مي‌دهد كه تابع جريمه در مساله پيش‌بيني بار بوضوح غيرخطي بوده و خطاهاي بزرگ مي‌توانند اثرات خطرناكي براي استفاده همگاني داشته باشد. ازاينرو، گاهي اوقات اندازه‌گيري ميانگين مربعات خطا[۲۳] (MSE) نيز توصيه مي‌شود، چون در اينصورت خطاهاي بزرگ بيشتر جريمه مي‌شوند[۲۶].

با اين اوصاف، از آنجايي كه الگوريتم SOM در زمان اجرا رابطه (۴) را مينيمم كرده و خطاهای بزرگ را لحاظ می‌كند، در اين تحقيق براي تعيين بهترين پيش‌بيني پيک بار از معيار MAPE استفاده مي‌شود، لازم بذكر است كه با كاهش اين معيار مدل بهبود مي‌يابد. معيار MAPE از طريق رابطه زير محاسبه مي‌شود:

$$MAPE = \frac{1}{M}\sum_{i=1}^{M}\frac{\left|actual(i)-forecast(i)\right|}{actual(i)}*100\% \qquad (۷)$$

كه M تعداد كل نقاط داده‌اي است، $actual(i)$ مقدار واقعي i امين است و $forecast(i)$ ، i امين پيش‌بيني است.

نتايج پيش‌بيني

همان طور كه پيش از اين بيان شد، پيش‌بيني پيك بار روز بعد با استفاده شبكه‌هاي عصبي پيشخوراند و چهار الگوريتم آموزشي OSS, BFGS, LM, RP انجام شد. نتايج نشان مي‌دهد كه هريك از اين الگوريتمها در بعضي از اين دسته‌ها بهترين جواب را ارائه مي‌كند. نتايج حاصل از شبكه عصبي پيشخوراند تلفيقي با مدل رگرسيون خطي و شبكه عصبي پيشخوراند تلفيقي بدون لحاظ ساير عوامل آب و هوايي علاوه بر دما مورد مقايسه قرار گرفته است. در انجام پيش‌بيني با استفاده از مدل رگرسيون خطي نيز علاوه بر عامل دما، عوامل آب و هوايي رطوبت و سرعت باد و پوشش ابر بعنوان عنصر ورودي مورد بررسي قرار گرفته‌اند، ليكن نتايج نشان داد كه با استفاده از اين مدل هيچيك از ورودیهاي ديگر بجز دما نمي‌تواند نتيجه پيش‌بيني را بهبود بخشد. جدول (۳) بهترين مقادير حاصل از پيش‌بيني با استفاده از شبكه عصبي پيشخوراند(با و بدون ساير عوامل آب و هوايي) و مدل رگرسيون خطي تلفيقي براي هر يك از ۱۲ دسته حاصل از دسته‌بندي را نشان مي‌دهد.

جدول ۳ : مقايسه نتايج بدست آمده از سه مدل پيش‌بيني.

نام دسته	شبكه عصبي پيشخوراند تلفيقي	شبكه عصبي پيشخوراند تلفيقي (بدون ساير عوامل آب وهوايي)	رگرسيون خطي تلفيقي
ايام عيد	۱,۳۲	۲,۰۶	۳,۴۱
دسته اول جمعه‌ها و ايام تعطيل	۲,۰۴	۲,۸۳	۲,۸۲
دسته دوم جمعه‌ها وايام تعطيل	۱,۲۲	۱,۶۶	۱,۶۱
دسته سوم جمعه‌ها و ايام تعطيل	۱,۸۱	۱,۸۶	۲,۱۳
دسته اول پنجشنبه‌ها	۰,۹۳	۱,۰۹	۱,۵۵
دسته دوم پنجشنبه‌ها	۰,۷۵	۰,۶۷	۱,۶
دسته سوم پنجشنبه‌ها	۰,۸۵	۰,۹۱	۱,۴۸
دسته‌چهارم پنجشنبه‌ها	۱,۲۳	۱,۲۷	۱,۵۴
دسته اول شنبه‌ها تا چهارشنبه‌ها	۱,۲۱	۱,۳۲	۱,۴۴
دسته دوم شنبه‌ها تا چهارشنبه‌ها	۱,۱۹	۱,۳۵	۲,۰۴
دسته سوم شنبه‌ها تا چهارشنبه‌ها	۱,۴۲	۱,۵۲	۱,۶۴
دسته چهارم شنبه‌ها تا چهارشنبه‌ها	۱,۳۴	۱,۴۷	۱,۴۹

همان طور كه مشاهده مي‌شود در تمامي دسته‌ها معيار عملكرد با بكارگيري مدل شبكه عصبي پيشخوراند تلفيقي نسبت به روش رگرسيون خطي تلفيقي جوابهاي بسيار

بهتري را ارائه مي‌كنند. در ضمن، معيار عملكرد بهبود قابل ملاحظه نتايج پيش‌بيني با ورود اطلاعات مربوط به ساير عوامل آب و هوايي به شبكه را نشان مي‌دهند. همچنين، جهت نمايش ميزان تاثيرگذاري دسته‌بندي ايام سال در بهبود پيش‌بيني پيك بار روز بعد، محاسبات با استفاده از شبكه عصبي پيشخوراند و بدون خوشه‌بندي انجام شده است. بطوريكه، پس از انجام پيش‌بيني با استفاده از چهار مدل، ميانگين وزني نتايج حاصل شده از هر يك دسته‌ها براي مقايسه عملكرد پيش‌بيني چهار مدل مورد استفاده در طول يكسال محاسبه شد. جدول (۴) نتايج كلي عملكرد چهار مدل پيش‌بيني را ارائه مي‌كند. آنچنان كه در جدول (۴) نشان داده مي‌شود متوسط خطاي پيش‌بيني مجموعه اعتبارسنجي با استفاده از شبكه عصبي پيشخوراند بدون استفاده از خوشه‌بندي برابر ۲,۰۴ بوده است كه اين مقدار با استفاده از تلفيق شبكه نقشه خودسازمانده و رگرسيون خطي به ۱,۷۸ درصد خطا تقليل پيدا كرده است. همچنين، بعد از تلفيق شبكه نقشه خودسازمانده با شبكه عصبي پيشخوراند (بدون ساير عوامل آب وهوايي) متوسط خطاي پيش‌بيني تا ۱,۵۳ درصد خطا كاهش يافته است.

جدول ۴ : مقايسه نتايج كلي بدست آمده از چهار مدل پيش‌بيني.

نوع مدل / معيار عملكرد	شبكه عصبي پيشخوراند تلفيقي	شبكه عصبي پيشخوراند تلفيقي (بدون ساير عوامل آب وهوايي)	رگرسيون خطي تلفيقي	شبكه عصبي پيشخوراند
MAPE	۱,۳۴	۱,۵۳	۱,۷۸	۲,۰۴

ليكن، مدل شبكه عصبي پيشخوراند تلفيقي پيشنهادي قادر است با ۱,۳۴ درصد خطا براي ما پيك بار روز بعد را انجام دهد. از اين رو، خوشه‌بندي ايام سال و لحاظ ساير عوامل آب و هوايي موجب بهبود چشمگيري در پيش‌بيني شده است.

نتيجه‌گيري

اين مقاله، يك مدل شبكه عصبي پيشخوراند تلفيقي براي پيش‌بيني پيك بار روزانه ارائه مي‌كند در اين تحقيق، ابتدا از يك نقشه خودسازمانده براي تعيين بهترين خوشه‌بندي براي تقسيم‌بندي هفته‌هاي سال براساس دو عامل پيك بار و دماي هوا در ساعت پيك‌بار استفاده شد. بدليل متفاوت بودن مقياس اين دو عامل، از نرمالسازي داده‌ها پيش از آغاز عمليات خوشه‌بندي استفاده شد. براي تعيين بهترين خوشه‌بندي از شاخص خوشه‌بندي ديويس-بولدين استفاده شد. آنگاه، دسته‌هاي حاصل از خروجي نقشه خودسازمانده اول توسط نقشه خودسازمانده ديگري براساس عامل پيك بار، هر يك به دسته‌هاي ديگري تقسيم شد كه در نهايت ۱۲ دسته حاصل شد. سپس با استفاده از شبكه عصبي پيشخوراند مبتني بر روشهاي BFGS, LM, RP OSS, عمل پيش‌بيني انجام گرفت. همچنين از PCA براي كاهش ابعاد ورودیها به شبكه و استفاده از معماري ساده‌تر استفاده شده است در اين تحقيق، نتايج حاصل از شبكه عصبي پيشخوراند تلفيقي با سه مدل رگرسيون خطي تلفيقي، شبكه عصبي پيشخوراند تلفيقي(بدون ساير عوامل آب وهوايي) و شبكه عصبي پيشخوراند بدون انجام خوشه‌بندي مقايسه و ملاحظه شد كه اولاً جوابهاي حاصل از شبكه عصبي پيشخوراند تلفيقي بسيار بهتر از مدل رگرسيون خطي تلفيقي است. ثانياً, عوامل رطوبت, سرعت باد و پوشش ابر بهبود قابل ملاحظه‌اي در پيش‌بيني بوجود آورده است. ثالثاً، با مقايسه نتايج حاصل از مدل شبكه عصبي پيشخوراند تلفيقي و شبكه عصبي پيشخوراند مي‌توان متوجه شد كه خوشه‌بندي موجب بهبود نتايج شده است.

تقدير و تشكر

تهيه‌كنندگان مقاله از شركت برق منطقه‌اي تهران و خصوصاً جناب آقاي نصيري براي تامين داده‌هاي پيك بار تشكر و قدرداني مي‌نمايند.

مراجع

1- International Energy Agency (online) (cited 4 November 2003). Available from <URL:http://www.iea.org>.

2 - Tzafestas, S. and Tzafestas, E. (2001). "Computational Intelligence Techniques for Short-Term Electric Load Forecasting." *Journal of Intelligent and Robotic Systems*, Vol. 31, No.7, PP.7–68.

3 - Metaxiotis, K., Kagiannas, A., Askounis, D. and Psarras, J. (2003). "Artificial intelligence in short term electric load forecasting: a state-of-the-art survey for the researcher." *Energy Conversion & Management*, Vol. 44, PP.1525-1534.

4 - Huang, H. G., Hwang, R. C. and Hsieh, J. G. (2002). "A new artificial intelligent peak power load forecaster based on non-fixed neural networks." *Electrical Power Energy System*, Vol. 24, PP.245-250.

5 - Hippert, H. S., Pedreira, C. E. and Souza, R. C. (2001). "Neural Networks for Short-Term Load Forecasting: A Review and Evaluation." *IEEE Transactions on Power Systems*, Vol. 16, No. 1, PP.44-55.

6 - Amjady, N. (2001). "Short-Term Hourly Load Forecasting Using Time-Series Modeling With Peak Load Estimation Capability." *IEEE Trans. Power Systems*, Vol.16, No.4, PP.798-805.

7 - Sadeghpour, H., Amin-Naseri, M. R. (2002). *Daily load forecasting using expert system in khorasan electricity network*, 17th International power system conference in Iran.

8 - Sayyad, S., Sayyad, J. (1995). *Intelligent load forecasting for power systems*, 5th electrical power distribution conference in Iran.

9 - Moghaddas Tafreshi, M. and Yarian, M. (1999). *Short term load forecasting using combined kohonen and perceptron neural networks*, 14th International power system conference in Iran.

10 - Carpinteiro, O. A. S. and Alves Da Silva, A. P. (2004). "A hierarchical neural model in short-term load forecasting." *Applied Soft computing*, Vol. 4, PP.405-412.

11 - Carpinteiro, O. A. S. and Alves Da Silva,A. P. (2001). "A hierarchical self-organizing map model in short-term load forecasting." *Journal of Intelligent and Robotic Systems*, Vol. 31, No.1-3, PP.105-113.

12 - Carpinteiro, O. A. S. and Alves Da Silva, A. P. (2000). "A hierarchical neural model in short-term load forecasting." *IEEE*, PP.120-124.

13 - Hsu, C. C. and Chen, C. Y. (2003). "Regional load forecasting in Taiwan-applications of artificial neural networks." *Energy Conversion & Management*, Vol. 44, PP.1941-1949.

14 - Huang H. G., Hwang, R. C. and Hsieh, J. G. (2002). "A new artificial intelligent peak power load forecaster based on non-fixed neural networks." *Electrical Power Energy System*, Vol. 24, PP.245-250.

15 - Iizaka, T., Matsui, T. and Fukuyama, Y. (2002). "A novel daily peak load forecasting Method using Analyzable structured neural network." *IEEE T&D asia yokohama*, October, 1-6.

16 - Saini, L. M. and Soni, M. K. (2002). "Artificial neural network based peak load forecasting using Conjugate Gradient Methods." *IEEE Transactions on Power Systems*, Vol. 17, No. 3, August. PP.907-912.

17 - Saini, L. M. and Soni, M. K. (2002). "Artificial neural network based peak load forecasting using Levenberg-Marquardt and quasi-Newton methods." *IEE Proc-Gener.Transm.Distrib*.

18 - Kim, C., Yu, I. and Song, Y. H. (2002). "Kohonen neural network and wavelet transform based approach to short-term load forecasting." *Electrical Power Energy System*, Vol. 63, PP.169-176.

19 - Mori, H. and Yuihara, A. (2001). "Deterministic Annealing Clustering for ANN-Based Short-Term Load Forecasting." *IEEE Transactions on Power Systems,* Vol. 16, No. 3, PP. 545-551.

20 - Amin-Naseri, M. R. and Soroush, A. R. (2006). "A Hybrid Neural Network Model for Daily Peak Load Forecasting Using a Novel Clustering Approach." *The IASTED conference Artificial Intelligence and Soft Computing,* PP.104-109.

21 - Oja, M., Kaski, S. and Kohonen, T. (2002). "Bibliography of Self-Organizing Map (SOM) Papers: 1998-2001 Addendum." *Neural Computing Surveys*, Vol. 3, PP.1-156.

22 - Vesanto, J. and Alhoniemi, E. (2000). "Clustering of the Self-Organizing Map." *IEEE Transactions on Neural Networks,* Vol. 11, No. 3, PP.586-600.

23 - Demuth, H. and Beale, M. (2004). *MATLAB 7.0/ Neural Network Toolbox*, version 4, The MathWorks, Inc., (CD-ROM),PP.1-840.

24 - Sharma, S. (1996). *Applied Multivariate Techniques*, First Edition, John Wiley & Sons, Inc.

25 - Hagan, M. T., Demuth, H. and Beale, M. (1996). *Neural Network Design*, USA, PWS Publishing Company.

26- Hippert, H. S., Pedreira, C. E. and Souza, R. C. (2001). "Neural Networks for Short-Term Load Forecasting: A Review and Evaluation." *IEEE Transactions on Power Systems*, Vol. 16, No. 1, PP.44-55.

واژه‌های انگلیسی به ترتیب استفاده در متن

1 - Artificial Intelligence
2 - Artificial Neural Networks
3 - Self-Organizing Map
4 - Feed forward
5 - Quasi-Newton
6 - Gray
7 - Steepest Descent
8 - Levenberg-Marquardt
9 - Broyden-Fletcher-Goldfarb-Shanno
10 - One Step Secant
11 - Deterministic Annealing
12 - Map Units
13 - Best Matching Unit
14 - Neighborhood Kernel
15 - Davies-Bouldin Index
16 - Spherical Clusters
17 - Random Order Incremental Training
18 - Lag
19 - Principal Component Analysis
20 - Rotated Component Matrix
21 - Kaiser-Meyer-Olkin Measure of Sampling Adequacy
22 - Mean Absolute Percentage Error
23 - Mean of Square Error