



پیش‌بینی ماهانه مصرف نفت سفید کل کشور با استفاده از شبکه عصبی بازگشتی

احمد کوچک‌زاده

دانشجوی دکتری، دانشگاه تربیت مدرس

kochaka@modares.ac.ir

محمد رضا امین‌ناصری

استادیار دانشگاه تربیت مدرس

Amin_nas@modares.ac.ir

واژه‌های کلیدی

پیش‌بینی مصرف نفت سفید، شبکه‌های عصبی بازگشتی، طراحی آزمایشات


چکیده

با توجه به نقش نفت سفید در تامین انرژی گرمایشی بخش‌های عمده‌ای از کشور که هنوز امکان گازرسانی به آنجا وجود نداشته، پیش‌بینی مصرف نفت سفید جهت انجام برنامه‌ریزی‌های آتی از جمله تخصیص بهینه آن در کل کشور امری با اهمیت می‌نماید. بررسی مصرف نفت سفید در کل کشور در طی سالهای گذشته نشان دهنده آنست که روند مصرف آن از یک الگوی چرخشی تبعیت می‌کند که ارتباط مستقیمی با برودت هوا و فصل‌های سال دارد. در پیش‌بینی کوتاه مدت با الگوهای چرخشی، روش‌های زیادی مبتنی بر سری‌های زمانی بسط و توسعه داده شده‌اند اما مدل‌های یاد شده به‌طور عمده روندهای خطی در سری‌های زمانی را کشف می‌کنند و در حالی که در دنیای واقعی اغلب روندها غیرخطی می‌باشند. از جمله ابزارهای که اخیراً کانون توجه بسیاری محققین قرار گرفته، شبکه‌های عصبی مصنوعی می‌باشد که از طریق آموزش، توانایی یادگیری از تجارب گذشته و بهبود سطح کارایی خود را دارند. به همین جهت در این تحقیق با استفاده از یادگیری «هدایت شده» یک مدل شبکه عصبی برای «پیش‌بینی ماهانه مصرف نفت سفید»، توسعه داده شده است و در ذیل این مدل برای شناخت عوامل موثر بر عملکرد شبکه عصبی، از طراحی آزمایشات بهره‌گیری شده است.




مقدمه

نفت سفید به عنوان یکی از منابع تامین کننده انرژی بخش خانگی و تجاری به طور عمده به منظور ایجاد گرمایش محیط، تامین آب گرم، پخت و پز و تامین روشنایی استفاده می‌شود. در شکل (۱) درصد خانوارهای معمولی ساکن برحسب نوع سوخت مصرفی برای ایجاد گرما و پخت پز نشان داده شده است.



شکل ۱: درصد خانوارهای معمولی ساکن برحسب نوع سوخت مصرفی برای ایجاد گرما و پخت پز^۱

با توجه به نقش نفت سفید در تامین انرژی بخشهای عمده‌ای از کشور که هنوز امکان گازرسانی به آنجا وجود نداشته است، پیش‌بینی مصرف نفت سفید جهت انجام برنامه‌ریزیهای آتی از جمله تخصیص بهینه آن در کشور امری ضروری به نظر می‌رسد. بررسی مصرف نفت سفید در کل کشور در طی سالهای اخیر نشان دهنده آنست که روند مصرف آن از یک الگوی چرخشی تبعیت می‌کند. در شکل (۲) مصرف ماهانه نفت سفید کل کشور در طی سالهای ۱۳۸۲-۱۳۷۶ نشان داده شده است.



شکل ۲: مصرف ماهانه نفت سفید در سالهای ۱۳۸۲-۱۳۷۶^۲

در ادامه در بخش دوم به ادبیات موضوع پیش‌بینی با شبکه‌های عصبی مصنوعی، در بخش سوم به توسعه مدل پیش‌بینی ماهانه مصرف نفت سفید و در انتها به نتیجه‌گیری خواهیم پرداخت.

۱- ماخذ: مرکز آمار ایران

۲- ماخذ: شرکت ملی پخش فراورده‌های نفتی؛ مرکز آمار و اطلاعات



۱- ادبیات موضوع پیش‌بینی با شبکه‌های عصبی مصنوعی^۳

شبکه‌های عصبی مصنوعی به جهت برخورداری از قابلیت‌های فراوان، کانون توجه بسیاری محققین قرار گرفته و در بسیاری از شاخه‌های علوم کاربردهایی در برداشته است [۱]. یکی از کاربردهای عمده شبکه‌های عصبی مصنوعی، پیش‌بینی می‌باشد. در واقع توانایی پیش‌بینی دقیق آینده، اساس بسیاری شاخه‌های علوم را تشکیل می‌دهد. با وجود اینکه در خصوص پیش‌بینی فعالیت‌های بسیاری در گذشته صورت گرفته، اما به سبب اهمیت موضوع هنوز این تحقیقات ادامه دارد.

پیش‌بینی برای مدت‌ها بر مبنای روش‌های خطی انجام می‌شد. اینگونه روش‌ها دارای این مزیت هستند که کاربرد و فهم آنها ساده است. اما باید توجه داشت که مدل‌های خطی محدودیت‌های بسیاری نیز دارند و قادر به لحاظ کردن روابط غیرخطی که بخش اعظمی از دنیای واقعی را تشکیل می‌دهند، نمی‌باشند. حتی تقریب‌های خطی صورت گرفته از روابط پیچیده غیر خطی نیز چندان رضایت بخش نبوده است. در اوایل دهه ۸۰، Makridakis روش‌های عمده پیش‌بینی خطی را با بیش از ۱۰۰۰ سری زمانی واقعی مورد آزمون قرار داد و به این نتیجه رسید که هیچ روش خطی وجود ندارد که بتواند در تمامی حالات مفید باشد [۲].

در این بین شبکه‌های عصبی مصنوعی امید تازه‌ای را در زمینه پیش‌بینی ایجاد کرد. ساختار غیرخطی شبکه‌های عصبی مصنوعی در بسیاری روابط پیچیده و غیرخطی دنیای واقعی دارای کاربرد می‌نموند. علاوه بر توانایی مدل‌سازی غیرخطی، شبکه‌های عصبی مصنوعی دارای خصوصیات ارزشمند دیگری در پیش‌بینی هستند که از آن جمله می‌توان به این مطلب اشاره داشت که شبکه‌های عصبی در واقع یک روش ناپارامتری مبتنی بر داده هستند که عاری از بسیاری فرضیات محدود کننده در خصوص داده‌ها می‌باشند.

در زمینه پیش‌بینی متداول‌ترین ترین شبکه مورد استفاده در تحقیقات، شبکه پیش‌خوراند^۴ می‌باشد. علاوه بر شبکه‌های عصبی مصنوعی پیش‌خوراند انواع دیگری از شبکه‌های عصبی مصنوعی نیز در پیش‌بینی استفاده شده است. به عنوان مثال شبکه عصبی بازگشتی^۵ در زمینه الگوهای غیرخطی پویا جایگزین خوبی برای شبکه پیش‌خوراند در پیش‌بینی سری‌های زمانی است [۳ و ۴ و ۵ و ۶ و ۷ و ۸ و ۹]. در شبکه عصبی بازگشتی بازخورهایی بین نرون‌های مختلف وجود دارد. خروجیها در این نوع شبکه می‌توانند مستقیماً به ورودیها بازخور بدهند که این کار منجر به یک بازخورد پویا بر روی خطای حاصل از الگوهای قبلی می‌گردد و بر همین اساس درست ماندن مزیتی که مدل‌های ARMA بر AR در پیش‌بینی دارند حاوی پویای بیشتری نسبت به شبکه‌های پیش‌خوراند می‌باشد. با این وجود تحقیقات چندان در بررسی مزیت نسبی شبکه‌های بازگشتی نسبت به شبکه‌های پیش‌خوراند در پیش‌بینی صورت نگرفته است. صعوبت در بکارگیری شبکه‌های بازگشتی می‌تواند ناشی از دو علت باشد. نخست آنکه شبکه‌های بازگشتی می‌توانند معماری‌های متفاوتی را بپذیرند و تعیین مناسب‌ترین ساختار بعضاً با مشکل روبرو می‌شود و دوم آنکه آموزش آن نیز مشکل است.

در ارتباط با پیش‌بینی مصرف فرآورده‌های نفتی تحقیقات زیادی در دهه‌های اخیر انجام گرفته است که نتایج متفاوتی در برداشته است اما شبکه عصبی نسبت به تکنیک‌های دیگر نظیر اقتصاد سنجی، مدل‌های Box و Jenkins و حتی تلفیق این تکنیک‌ها نوعاً از عملکرد بهتری برخوردار بوده است [۱۰ و ۱۱]. دلیل این امر ناشی از سه عامل است؛ اول فرضیات محدود کننده این مدل‌ها، دوم صعوبت در تهیه داده‌های مربوط به این مدل‌ها و سوم آنکه این مدل‌ها در لحاظ کردن طبیعت غیر خطی مشاهدات که در دنیای واقعی وجود دارند از ناتوانی نسبی برخوردارند.

3 - Artificial Neural Network

4 - Feed Forward Neural network


5 - Recurrent Neural Network

۲- توسعه مدل پیش‌بینی

در طراحی معماری شبکه عصبی به منظور پیش‌بینی پارامترهای زیادی از قبیل تعداد و نوع ورودیها، تعداد نرونهای لایه‌های پنهان، تابع انتقال، توابع پیش‌پردازش و الگوریتمهای آموزش مطرح می‌شوند که باید با انجام آزمون‌های هدفمند، بهترین مقدار را برای آنها بدست آورد. برای این کار در این تحقیق بر اساس تکنیک طراحی آزمایشات^۶ مقادیر بهینه برخی پارامترهای شبکه عصبی مورد استفاده در پیش‌بینی بدست آمده است و در خصوص بقیه پارامترها به ادبیات موضوع پیش‌بینی اکتفا شده است. در ادامه به جزئیات توسعه مدل پیش‌بینی پرداخته می‌شود.

۲-۱- ورودیها

تعداد گره‌های ورودی شاید مهمترین جنبه در طراحی و بکارگیری موفق شبکه عصبی در پیش‌بینی است. تعیین مجموعه‌ای مناسب از متغیرهای ورودی فاکتور مهمی در استخراج روابط لازم جهت پیش‌بینی موفق است. تجربه نشان داده است که لایه ورودی از لایه پنهان نیز مهم‌تر است و بنابراین در تعیین لایه ورودی بویژه در خصوص پیش‌بینی سریهای زمانی باید دقت مضاعفی به خرج داد [۱۲]. در پیش‌بینی ماهانه مصرف نفت سفید از دو نوع متغیر بنیادی شامل سال، فصل، ماه، حداکثر و حداقل دمای هوا در تمامی ایستگاههای سینوپتیک کشور و مقادیر تاخیر یافته به‌عنوان ورودی استفاده شده است. برای تعیین مقادیر تاخیر یافته، از نمودار تابع خود همبستگی جزئی^۷ که در مدل‌های ARIMA برای تعیین ترمهای اتورگرسیو استفاده می‌شود، بهره‌گیری شده است. در شکل (۳)، PACF مربوط به مصارف ماهانه نفت سفید در کل کشور آمده است.



شکل ۳: تابع خود همبستگی جزئی برای مصارف ماهانه نفت سفید

با توجه به نمودار فوق مشاهده می‌شود که داده‌های مربوط به دو ماه قبل نسبت به ماه جاری بیشترین همبستگی را با مصرف ماه جاری دارند.

6 - Design of Experiment (DOE)

7 - Partial Auto Correlation Function(PACF)



۲-۲- اندازه و تعداد داده‌ها

از آنجا که شبکه‌های عصبی مصنوعی مبتنی بر داده هستند، آماده سازی داده‌ها یک قدم بحرانی و در واقع کلید موفقیت در استفاده از شبکه عصبی می‌باشند. بدون مجموعه‌ای از داده‌های مناسب و کافی غیر ممکن است که بتوان به یک پیش‌بینی موفق نائل آمد. در آماده‌سازی داده‌ها دو نکته حائز اهمیت است. نخست اندازه و تعداد داده‌ها. اگرچه قانون خاصی در این ارتباط وجود ندارد اما مزیت تعداد داده‌های زیاد آنست که علاوه بر تخمین پارامترهای زیادتر گاهی لازم است که داده‌ها را به چند بخش تقسیم کرد تا بتوان بر مشکل انطباق بیش از حد^۱ مدل بر داده‌ها فائق آمد، انتخاب مدل، مقایسه و ارزیابی آن را به نحو مقتضی انجام داد. هرچه قدر تعداد داده‌ها بیشتر باشد می‌توان در خصوص تقریب ساختار متضمن در مدل اطمینان بیشتری حاصل کرد. دومین نکته افزاز داده‌ها به چندین قسمت است. نوعاً برای شبکه‌های عصبی مصنوعی باید داده‌ها را به دو قسمت داده‌های آموزش و داده‌های اعتبارسنجی تقسیم کرد. داده‌های آموزش برای تعیین مقادیر پارامترهای شبکه و داده‌های اعتبارسنجی برای ارزیابی توانایی مدل بکار می‌رود. اگرچه اجماعی بر سر چگونگی افزاز داده‌ها وجود ندارد اما Granger پیشنهاد داده است که نسبت ۸۰ به ۲۰ در نظر گرفته شود [۱۳]. در این تحقیق نیز در ارتباط با اندازه داده‌ها مصارف مربوط به سالهای ۱۳۸۲-۱۳۷۶ یعنی ۸۴ نقطه در نظر گرفته شده است. در ارتباط با مشکل انطباق بیش از حد در آموزش شبکه عصبی و افزاز داده‌ها به دو مجموعه آموزش و اعتبارسنجی نیز به ادبیات موضوع اکتفا گردیده از نسبت ۸۰ به ۲۰ بهره گرفته شده است.

۲-۲- لایه پنهان

اگرچه در انتخاب تعداد لایه‌های پنهان و نیز تعداد گره‌های هر لایه، اصولاً یک انعطاف پذیری وجود دارد اما با این وجود در بسیاری کاربردهای پیش‌بینی بر اساس اصل امساک^۲ از یک لایه و تعداد کمی گره استفاده می‌شود. در عمل تعداد لایه‌های پنهان اغلب بر اساس عملکرد مجموعه‌ای که بر مبنای آن اعتبارسنجی صورت می‌گیرد تعیین می‌شود. در این خصوص Zhang شبکه‌ای با یک لایه پنهان و حداکثر ۲n گره را که در آن n تعداد گره‌های لایه ورودی است پیشنهاد داده است [۱۲]. در این تحقیق برای بررسی تاثیر لایه پنهان دوم در مدل طراحی آزمایشات، از شبکه‌ای با دولایه نیز استفاده شده است. اما به سبب اجتناب از پیچیدگی که غیر ضروری بنظر می‌رسد تعداد نرونهای لایه پنهان دوم حداکثر ۲ گره در نظر گرفته شده است. در خصوص تعداد گره‌های لایه پنهان اول نیز بر اساس پیشنهاد Zhang، از حداکثر دو برابر تعداد گره‌های لایه ورودی در شبکه بهره گیری شده است. لازم بذکر است در عمل اضافه نمودن تعداد گره‌های لایه پنهان اول در برخی موارد عملکرد شبکه را بدتر می‌نماید.

۲-۳- توابع پیش پردازش

اهمیت پیش پردازش داده‌ها در تسهیل یادگیری شبکه، فراهم آوردن ملزومات الگوریتم آموزش و اجتناب از پیچیدگیهای محاسباتی نمود پیدا می‌کند. البته لازم بذکر است که تاثیر نرمالیزه کردن داده‌ها بر روی یادگیری و چگونگی عملکرد شبکه بدرستی معلوم نشده است. برای مثال در مدل سازی پیش‌بینی فصلی، Goit براین باور است که به لحاظ اینکه شبکه عصبی به‌خوبی تمامی الگوها را تشخیص می‌دهد، پیش پردازش پردازش داده‌ها لازم نیست [۱۴].

بر این اساس در پیش‌بینی مصرف نفت سفید از دو تابع پیش‌پردازش MinMax و STDV به‌صورت ذیل بهره‌گیری شده است.

8 - Over Fitting Problem

9 - Parsimonious



$$X_n = \frac{X - X_{Min}}{X_{Max} - X_{Min}}$$

$$X_n = \frac{X - X_{Mean}}{StdDev}$$

در تابع اول مقادیر ورودی، در بازه [۰,۱] بر گردانده می‌شود و در تابع دوم تبدیلی که بر روی داده‌ها انجام می‌شود سبب آن می‌شود که میانگین داده‌ها صفر و انحراف معیار آنها برابر یک گردد. برای تعیین اینکه از کدام تابع پیش‌پردازش استفاده شود چنانچه بیان شد از مدل طراحی آزمایشات استفاده شده که در پی خواهد آمد. ذکر این نکته لازم است که به جهت آنکه شبکه عصبی می‌تواند الگوهای نهفته در داده‌ها را کشف کند لذا غیر فصلی کردن داده‌ها لازم نیست.

۲-۴- تابع تبدیل

در خصوص پیش‌بینی متداول‌ترین و پر استفاده‌ترین تابع تبدیل برای گره‌های لایه پنهان تابع لجستیک و یا هایپربولیک است و برای گره‌های خروجی عموماً از تابع همانی و یا خطی استفاده می‌شود. در این تحقیق نیز از این دو تابع تبدیل استفاده شده است.

۲-۵- الگوریتم‌های آموزش

زمانی که معماری یک شبکه جهت پیش‌بینی مشخص شد باید تحت آموزش قرار گیرد تا بر طبق الگوی نهفته در داده‌ها پارامترهای شبکه تخمین زده شود. برای دستیابی به عملکردی مناسب طبعاً باید از الگوریتم یادگیری مناسبی بهره جست. آموزش شبکه عصبی می‌تواند به عنوان یک بهینه‌سازی غیرخطی تلقی شود و لذا الگوریتم‌های یادگیری و اوزان اولیه متفاوت بر روی نتایج تاثیر خواهند گذاشت. در این رابطه مطابق با تحقیقات Zhang در پیش‌بینی، الگوریتم لوبنبرگ_مارکوارت^{۱۰} به لحاظ سرعت و اشغال حافظه کمتر دارای مطلوبیت بیشتری می‌باشد [۱۲]. در این تحقیق نیز از الگوریتم مورد اشاره در آموزش شبکه عصبی استفاده شده است.

۲-۶- شاخصهای ارزیابی عملکرد شبکه عصبی

در ارزیابی عملکرد شبکه عصبی از توابعی نظیر مجموع مربعات خطا، میانگین مربعات خطا^{۱۱}، میانگین درصد خطا^{۱۲}، میانگین انحرافات مطلق^{۱۳} و ... استفاده می‌شود که در مدل پیش‌بینی ارائه شده از مجموع مربعات خطا (SSE) استفاده گردید.

۲-۷- معماری شبکه عصبی

10 - Levenberge - Marquardt Algorithm

11 - Mean square Error (MSE)

12 - Mean Absolute Percentage Error(MAPE)

13 - Median Absolute Percentage Error(MdAPE)

14 - Mean Absolute Deviation (MAD)



طراحی و انتخاب معماری شبکه‌های عصبی مصنوعی، مشکل‌ترین قسمت انجام کار است و پارامترهای زیادی اعم از نوع شبکه، تعداد گره‌های لایه ورودی، تعداد لایه‌های پنهان، تعداد گره‌های لایه پنهان، نوع توابع تبدیل، نوع توابع پیش‌پردازش و الگوریتمهای آموزش شبکه مطرح می‌باشند. اگرچه در این ارتباط، تعداد زیادی قوانین سرانگشتی وجود دارد اما قابلیت تعمیم به وضعیتی جدید را ندارند [۱۲].

در این تحقیق برای تعیین پارامترهای معماری شبکه‌های عصبی، فاکتورهای نوع شبکه، تعداد نرونهای لایه پنهان اول، تعداد نرونهای لایه پنهان دوم، تابع پیش‌پردازش و تابع انتقال از یک مدل طراحی آزمایشات استفاده شده است که در آن سطوح هر یک از فاکتورهای مورد اشاره بر طبق جدول (۱) می‌باشد. شایان ذکر است در ارتباط با بقیه پارامترها نظیر الگوریتم آموزش و همچنین انتخاب سطوح فاکتورهای معماری شبکه‌های عصبی به ادبیات موضوع اکتفا گردیده است.

نوع شبکه		تعداد نرون های لایه پنهان دوم	تابع پیش‌پردازش		تابع تبدیل		تعداد نرونهای لایه پنهان اول
پیش خوراند	بازگشتی	۰, ۱, ۲	STDV	MinMax	LogSig	TanSig	۵, ۶, ۷, ۸, ۹, ۱۰, ۱۱, ۱۲, ۱۳, ۱۴

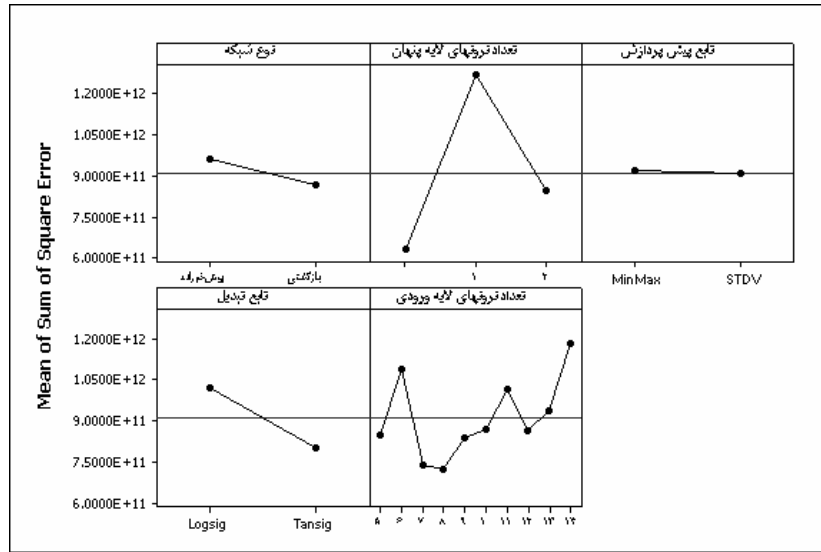
جدول ۱: فاکتور ها و سطوح مربوط به آنها مورد استفاده در طراحی آزمایشات

در طراحی آزمایشات روش کار بدین صورت است که متغیری تحت عنوان متغیر پاسخ که نمایانگر عملکرد سیستم مورد مطالعه می‌باشد و عواملی که بر روی این متغیر تاثیرگذار می‌باشند تعیین می‌گردند. آنگاه با یک سری آزمایشهای سیستماتیک بر اساس ترکیبهای متفاوت عوامل یاد شده و انجام آنالیز واریانس تاثیر این عوامل بر روی متغیر پاسخ سنجیده می‌شود. نتایج حاصل از طراحی آزمایشات در دو سرفصل قرار می‌گیرد؛ نخست تاثیر یا عدم تاثیر هر یک از عوامل و دوم وجود و یا عدم وجود تاثیرات متقابل عوامل مختلف بر روی متغیر پاسخ. تاثیر و یا عدم تاثیر هر یک از عوامل از روی نمودار تاثیرات ثابت بدین صورت تشخیص داده می‌شود که در صورتی که خط برازش شده در ارتباط با هر عامل، موازی محور Xها باشد فاقد تاثیر و در غیر اینصورت دارای تاثیر می‌باشد. در ارتباط با تاثیرات متقابل نیز بر اساس نمودار تاثیرات متقابل در صورتی که خطوط برازش شده در ارتباط با هر دو عامل و یا چند عامل در بین سطوح مختلف متقاطع باشند دو یا چند عامل یاد شده دارای تاثیر متقابل هستند و در غیر اینصورت تاثیر متقابل بین عامل و یا عوامل مورد اشاره وجود ندارد.

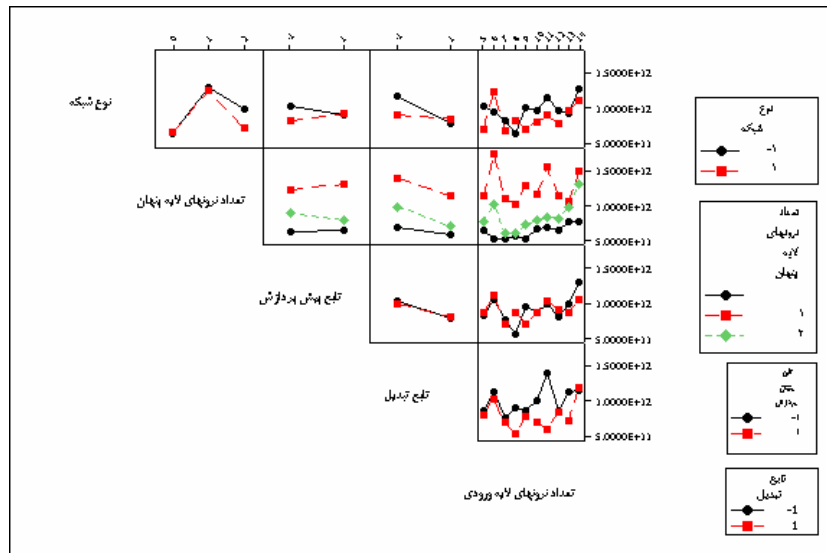
در تنظیم پارامترهای شبکه عصبی مورد استفاده در پیش‌بینی مصرف نرفسفید از مجموع مربعات خطا (SSE) به عنوان متغیر پاسخ استفاده شده است. به منظور انجام مدل طراحی آزمایشات، بر اساس ترکیبهای متفاوت جدول (۱) و ۵ بار تکرار که در مجموع ۱۲۰۰ بار اجرا برآورد می‌شود، شبکه عصبی ایجاد و مورد آموزش قرار گرفت. در شکل‌های (۴) و (۵) نمودار اثرات اصلی^{۱۵} و اثرات متقابل^{۱۶} مدل طراحی آزمایشات آمده است.

15 - Main Effect

16 - Interaction Effect



شکل ۴: نمودار اثرات اصلی مدل طراحی آزمایشات



شکل ۵: نمایش اثرات متقابل مدل طراحی آزمایشات

با توجه به اینکه در شکل (۵) خطوط تقریباً با هم موازی هستند می‌توان از اثرات متقابل چشم‌پوشی کرده و با استفاده از شکل (۴) ترکیب بهینه و ساختار مطلوب شبکه عصبی به صورت جدول (۲) می‌باشد.

نوع شبکه	تعداد لایه پنهان	تابع پیش‌پردازش	تابع تبدیل	تعداد نرون‌های لایه پنهان اول
بازگشتی	۱	تاثیری بسزایی ندارد	Tan Sig	۷,۸

جدول ۲: ساختار مطلوب شبکه عصبی به منظور پیش‌بینی مصرف نفت سفید



بعد از فرآیند مدل‌سازی، به سبب آنکه شبکه عصبی در واقع جانشین غیر خطی برای مدل‌های آماری سنتی است عملکرد آن را می‌توان با این گونه مدل‌ها سنجید. چنانچه Adya ادعا کرده است در صورتی که این مقایسه صورت نگیرد نمی‌توان با قاطعیت در مورد ارزشمندی شبکه عصبی اظهار نظری کرد [۱۵]. با اجرای متعدد شبکه عصبی بر اساس جدول (۲) مقادیر شاخص‌های ارزیابی عملکرد شبکه عصبی در جدول (۳) آمده است.

میانگین درصد خطا	میانگین درصد خطا	R^2 مجموعه آموزش	R^2 مجموعه اعتبارسنجی
۶٪	۸٪	۹۸٪	۹۶٪

جدول ۳: شاخص‌های ارزیابی عملکرد شبکه عصبی

برای مقایسه مدل شبکه‌عصبی با سایر مدل‌های متداول از دو نوع مدل‌های باکس و جنکینز و رگرسیون استفاده شده که نتایج آن بر اساس میانگین درصد خطا در جدول (۴) آمده است.

نوع مدل	میانگین درصد خطا
SARIMA(2,1,0)	۱۲٪
رگرسیون	۱۳٪
شبکه عصبی	۵٪

جدول ۴: مقایسه شبکه عصبی با مدل‌های متداول موجود

در ارتباط با مدل رگرسیون که در جدول (۴) آمده از مدل ذیل استفاده شده است.

$$Y_t = x_{Year,t} + x_{Season,t} + x_{Month,t} + x_{MaxT,t} + x_{MinT,t} + Y_{t-1} + Y_{t-2} + \varepsilon_t$$

که در آن متغیرها عبارتند از:

$x_{Year,t}$: اندیس سال

$x_{Season,t}$: اندیس فصل

$x_{Month,t}$: اندیس ماه

$x_{MaxT,t}$: حداکثر دمای گزارش شده در کلیه ایستگاه‌های سینوپتیک کشور

$x_{MinT,t}$: حداقل دمای گزارش شده در کلیه ایستگاه‌های سینوپتیک کشور


Y_{t-1} : مصرف ماه گذشته

Y_{t-2} : مصرف دو ماه گذشته

ε_t : عبارت خطا



در شکل (۶) مقایسه بین پیش‌بینی حاصل از شبکه عصبی و مقادیر واقعی آمده است.



شکل ۶: مقایسه مقادیر واقعی و پیش‌بینی حاصل از شبکه‌های عصبی

۳- نتیجه‌گیری

در طی این مقاله با استفاده از شبکه عصبی مدلی جهت پیش‌بینی مصرف ماهانه نفت سفید برای کل کشور ارائه گردید. در توسعه مدل شبکه عصبی پارامترهایی زیادی مطرح می‌شوند که به نوعی عملکرد شبکه عصبی متاثر از این پارامترها می‌باشد. این پارامترها شامل مواردی از قبیل نوع شبکه مورد استفاده، متغیرهای لایه ورودی، تعداد لایه‌های پنهان و تعداد گره‌های (نرون‌ها) لایه‌های پنهان، توابع تبدیل، الگوریتم‌های یادگیری، توابع پیش‌پردازش و چگونگی افزایش داده‌ها به مجموعه داده‌های آموزش و اعتبار سنجی می‌باشد. در این تحقیق با نظر به ادبیات موضوع برخی از این پارامترها ثابت در نظر گرفته شده و برای بقیه پارامترها شامل نوع شبکه مورد استفاده، تعداد لایه پنهان و تعداد نرون‌های لایه‌های پنهان، نوع پیش‌پردازش نوع تابع تبدیل یک مدل طراحی آزمایشات به انجام رسید و با توجه به نتایج حاصل از آن ساختار مطلوب شبکه عصبی ترسیم گردید. به عنوان تحقیقات آتی می‌توان اولاً پارامترهای بیشتری را به عنوان فاکتورهای طراحی آزمایشات در نظر گرفت و ثانیاً سطوح بیشتری برای مدل ملحوظ نمود.



منابع و مراجع

- ۱- Widrow, B., Rumelhart, D., Neural network: Application in industry, business and science, Communications of the ACM 37(3), 1994, 93-105.
- 2- Makridakis, S., Anderson, A., & Carbone, R., The accuracy of extrapolation (time series) methods, Journal of Forecasting, 1(2), 1982, 111-153.
- 3- Kermanshahi, B., Recurrent neural network for forecasting next 10 years loads of nine Japanese utilities, Neurocomputing, 23, 1998, 125-133.
- 4- Kuan, C. L., Forecasting exchange rates using feed forward and recurrent neural network, Journal of Applied Econometrics 10, 1995, 347-36.
- 5- Connor, J. T., Martin, R. D., & Atlas, L.E. ,Recurrent neural network and robust time series prediction, IEEE Transaction on neural network, 16 ,1994, 71-83.
- 6- Mediros, M. C. P., C.E., What are the effects of forecasting linear time series with neural network? Engineering Intelligent Systems 4, 2001, 237-424.
- 7- Parrlos, A. G., Rais, O.T. , & Atiya, A.F. , Multi step ahead prediction using dynamic recurrent neural network, Neural Network 13, 2000, 765-786.
- 8- Husken, M. S., Recurrent neural network for time series classification, Neurocomputing, 50, 2003, 223-235.
- 9- Vermark, J. B., Recurrent neural network for short term load forecasting." IEEE Transaction on Power System, 1, 13, 1998, 126-132.
- 10- Jebaraj, S., Iniyar, S., A Review of Energy Models, Renewable and Sustainable Energy review, 15, 2004, 56-69.
- 11- Box, G. E., Jenkins, G. M., Time Series Analysis: Forecasting and Control", San Francisco, 1976.
- 12- Zhang, G. P., An investigation of neural network for linear time series forecasting, Computers and Operation Research 28, 2001, 1183-1202.
- 13- Granger, C. W. J., Strategies for modeling nonlinear time-series relationship, The Economic Record, , 69 ,206, 1993, 233-238.
- 14- Gorr, L., Research prospective on neural network forecasting, International Journal of Forecasting, 10, 1993, 1-4.
- 15- Adya, M., How effective are neural network at forecasting and prediction? A review and evaluation, Journal of Forecasting, 17, 1998, 481-495.