

مدل طراحی بهینه معماری برای شبکه‌های عصبی مصنوعی و بهکارگیری آن در پیش‌بینی مصرف ماهانه نفت‌گاز کل کشور

محمد رضا امین‌ناصری^{*}، احمد کوچک‌زاده^{*}

۱- دانشیار مهندسی صنایع، دانشگاه تربیت مدرس، تهران، ایران

۲- دانشجوی دکتری تخصصی، مهندسی صنایع، دانشگاه تربیت مدرس، تهران، ایران

پذیرش: ۸۶/۱۲/۷

دریافت: ۸۶/۲/۲۵

چکیده

یکی از گامهای مهم در توسعه شبکه‌های عصبی مصنوعی طراحی معماری شبکه است که تأثیر زیادی بر عملکرد شبکه دارد. در طراحی معماری شبکه‌های عصبی مصنوعی، عواملی از قبیل تعداد لایه‌های پنهان، تعداد نرون‌ها در هر لایه، توابع تبدیل و الگوریتم آموزش باید تعیین شوند. محققان در طراحی معماری شبکه به‌طور عمده از طریق سعی و خطا عمل می‌کنند و یا اینکه اثر متقابل بین عوامل مختلف در طراحی معماری شبکه را در نظر نمی‌گیرند. در این تحقیق، یک مدل مبتنی بر تکنیک طراحی آزمایشها برای طراحی بهینه معماری شبکه عصبی با یادگیری تحت ناظارت، با توجه به اثر متقابل بین عوامل ذکر شده، ارائه می‌شود.

در این تحقیق، از مدل پیشنهادی برای طراحی معماری شبکه عصبی به منظور پیش‌بینی مصرف نفت‌گاز کل کشور استفاده شده است. به‌منظور مقایسه عملکرد مدل پیشنهادی با استفاده از روش سعی و خطا به‌عنوان یکی از روشهای مرسوم در طراحی معماری، یک مدل شبکه عصبی برای پیش‌بینی مصرف نفت‌گاز توسعه داده شده و طی آن برتری مدل پیشنهادی نشان داده شده است. همچنین برای مقایسه عملکرد شبکه عصبی با روشهای آماری، دو مدل با استفاده از رگرسیون و ARIMA طراحی شده‌اند. نتایج به دست آمده در پیش‌بینی مصرف نفت‌گاز در این بخش نیز نشان می‌دهد که پیش‌بینی با شبکه عصبی طراحی شده جوابهای بهتری دارد.

کلید واژه‌ها: معماری شبکه‌های عصبی مصنوعی، طراحی آزمایشها، پیش‌بینی، مصرف نفت‌گاز.



۱- مقدمه

پس از توسعه الگوریتم پس انتشار خطأ^۱، برای آموزش شبکه عصبی پیش خوراند^۲، شبکه عصبی مصنوعی به صورت فزاینده‌ای در انواع مسائل مهندسی و تجارت مورد توجه و استفاده قرار گرفت [۱۰۵-۹۳، ص۲۱]. یکی از عمدترين موارد کاربرد شبکه عصبی مصنوعی، پیش‌بینی است. اگرچه در طی سالهای متعدد استفاده از مدل‌های آماری خطی در پیش‌بینی مرسوم بوده است، اما این مدل‌ها علی‌رغم برخورداری از مزایایی از قبیل سادگی و تعداد نرم‌افزارهای تجاری، توانایی در نظرگرفتن روابط غیرخطی را -که اساس دنیای واقعی را تشکیل می‌دهند- ندارند [۳]. در واقع استفاده روزافزون از شبکه عصبی در پیش‌بینی از این واقعیت ناشی می‌شود که شبکه عصبی، یک مدل مبتنی بر داده با قابلیت الگوبرداری غیرخطی و عاری از بسیاری فرضیه‌های محدودکننده است. در این ارتباط، هورانگ، به مقایسه عملکرد شبکه عصبی و مدل‌های سری زمانی ARMA(p,q) به صورت تجربی پرداخت و در آن نشان داد که عموماً شبکه‌های عصبی مصنوعی عملکرد بهتری نسبت به مدل ARMA(p,q) دارند [۴، صص ۲۷۳-۲۸۹]. Zhang و همکاران به بررسی تجربی عملکرد شبکه عصبی در پیش‌بینی سری‌های زمانی غیرخطی در مقایسه با مدل‌های خطی مرسوم پرداخته و نشان دادند که شبکه‌های عصبی مصنوعی عملکرد بسیار بهتری داشته‌اند [۵، صص ۳۶-۳۸]. Marquez با مقایسه رگرسیون، یکی دیگر از ابزارهای متدائل در پیش‌بینی، نشان داد که شبکه‌های عصبی به لحاظ قابلیت انطباق بر داده‌ها، مانند مدل رگرسیون عمل می‌کنند [۶].

یکی از موضوعات تحقیقی مهم در ادبیات شبکه عصبی مصنوعی، طراحی معماری شبکه عصبی است. در ادبیات طراحی معماری شبکه عصبی، عموماً، عواملی از قبیل تعداد لایه‌های پنهان، تعداد نرون‌ها در هر لایه و توابع انتقال مطرح می‌شوند. محققان در طراحی معماری شبکه عصبی، از رویکردهای متفاوتی استفاده کرده‌اند: ۱- رویکرد سعی و خطأ که در آن برای تعیین معماری شبکه عصبی، ترکیب‌های متعددی مورد آزمایش قرار می‌گیرد و با مقایسه عملکرد هر ترکیب با سایر ترکیبها، معماری شبکه تعیین می‌شود. Zhang و همکاران به بررسی تأثیر نرون‌های لایه ورودی و نرون‌های لایه مخفی در سری‌های زمانی غیرخطی پرداخته و تأثیر هر عامل را مستقل و بدون درنظرگرفتن تأثیر متقابل با عوامل دیگر، بررسی

1. Back propagation algorithm

2. Feed forward Neural network

کرده و در تعیین معماری شبکه، از طریق سعی و خطا عمل کردند^۵. روش سعی و خطا، معماری بهینه را تضمین نمی‌کند و به خبرگی فرد، بستگی دارد؛ ۲- تکنیکهای سازنده و یا تکنیک هرس^۱ که بر پایه اضافه و یا حذف یک نرون از معماری اولیه شبکه با توجه به تأثیر آن بر عملکرد شبکه، قرار دارد. در این تکنیک، در زمانی که میانگین مربعات خطای شبکه، از یک مقدار از پیش تعیین شده بزرگتر باشد، یک نرون به شبکه اضافه می‌شود و در حالتی که وزنهای شبکه با اضافه کردن نرون مزبور، در تعداد زیادی تکرار، تغییر نکند و یا خطای شبکه به میزان قابل توجهی بهبود نیابد، از شبکه حذف می‌شود. مشهورترین الگوریتمهای سازنده روش DNC^۲ و روش CC^۳ است که در روش DNC یک شبکه با یک لایه پنهان ساخته می‌شود و در روش CC یک شبکه با چندین لایه پنهان ساخته می‌شود^۷. روش DNC در یادگیری مسائل پیچیده با مشکل رو برو می‌شود^۸. با افزایش تعداد لایه‌های پنهان و بروز پدیده انطباق بیش از حد بر داده‌ها، قابلیت تعمیم در شبکه حاصل از روش CC در برخی موارد تنزل می‌یابد^۹. معمول Islam Muras و CNNDA^۴ روش CC را برای توسعه یک شبکه با دولایه پنهان ارائه دادند^۹. در روش CNNDA، ابتدا نرون‌ها یکی پس از دیگری به یک شبکه با دولایه پنهان اضافه می‌شوند، آنگاه پس از همگرایی شبکه و دستیابی به نتیجه مطلوب (تا زمانی که جواب شبکه به میزان قابل توجهی تنزل پیدا نکرده) به هرس و حذف نرون‌ها و اتصالات شبکه ادامه می‌دهد^{۱۰}. از آنجا که این روشها مبتنی بر روش نزول گرادیان است، نمی‌توان جواب بهینه کلی^۵ را تضمین کرد و ممکن است پاسخ نهایی، یک جواب بهینه محلی باشد؛ ۳- الگوریتم ژنتیک، که در آن با تغییر تعداد لایه‌های پنهان و تعداد نرون‌های هر لایه با استفاده از عملکردهای الگوریتم ژنتیک، فضای گزینه‌های مختلف معماری شبکه، براساس تابع هدف معماری شبکه، جستجو می‌شود و بهترین معماری انتخاب می‌شود. میلر و همکاران با رمزگذاری الگوی اتصالات شبکه از الگوریتم ژنتیک در طراحی معماری شبکه عصبی استفاده کردند^{۱۱}. Schaffer و همکاران نیز از الگوریتم ژنتیک براساس روش رمزگذاری مستقیم برای تعیین دامنه نرخ یادگیری در

-
1. Pruning algorithm
 2. Back propagation algorithm
 3. Feed forward Neural network
 4. Feed forward Neural network
 5. Global Optimal Solution



الگوریتم پس انتشار خط، تعداد نرونها لایه پنهان و دامنه وزن‌های اولیه در شبکه پیش‌خواراند استفاده کردند [۱۲، صص ۲۴۴-۲۴۸]. Gencay و Arifovic از روش Schaffer برای تعیین دامنه وزن‌های اولیه شبکه، ساختار اتصالات شبکه، تعداد نرونها لایه پنهان و نوع ورودی‌ها در یک شبکه پیش‌خواراند با یک لایه پنهان استفاده کردند [۱۳، صص ۵۷۴-۵۹۴]. Benardos و Vosniakos برای تعیین تعداد لایه‌های پنهان و تعداد نرونها لایه پنهان به صورتی که خطای حاصل از آموزش و همچنین قابلیت تعمیم حداقل شود، از الگوریتم ژنتیک استفاده کردند [۱۴]. استفاده از الگوریتم ژنتیک در طراحی معماری بسیار زمان بر است و پارامترهای الگوریتم ژنتیک، به وسیله کاربر تعیین می‌شود [۱۵، صص ۶۲۵-۶۴۵]. همچنین در الگوریتم ژنتیک، عوامل دیگر نظریه الگوریتم آموزش، تابع تبدیل و اثر متقابل بین عوامل مختلف در نظر گرفته نمی‌شود؛ ۴- روش تاگوچی^۱ که بر اساس آن با انجام آزمایش‌های هدفمند از بین ترکیب‌های متعدد، ترکیب بهینه انتخاب می‌شود. Khaw و همکاران از این روش در تعیین تعداد لایه‌های مخفی، تعداد نرونها در هر لایه و اندازه مجموعه آموزش در یک شبکه پیش‌خواراند، استفاده کردند [۱۶، صص ۲۲۵-۲۴۵]. Lin و Chen و Lin و Tseng از این روش برای طراحی معماری شبکه LVQ^۲ استفاده کردند [۱۷، صص ۲۲۶-۱۸۱، صص ۳-۱۴]. از این روش در طراحی معماری شبکه نقشه خود سازمانده^۳ استفاده کردند [۱۹، ص ۸۵-۹۴]. این روش اثر متقابل بین عوامل مختلف را در نظر نمی‌گیرد و از پشتونه آماری لازم برخوردار نیست؛ ۵- سایر تکنیک‌ها نظریه تجزیه کانونی^۴، معیار اطلاعاتی شبکه^۵، الگوریتم چندجمله‌ای زمانی^۶ [۲۰، صص ۲۹۱-۳۰۰، ۲۱؛ ۸۶۵-۸۷۲، صص ۳۵-۵۴] هیچ‌کدام از این روشها، جواب بهینه را در همه حالات تضمین نمی‌کند [۲۲، صص ۳۵-۶۲].

روشهای ذکر شده، اولاً به‌طور عمده نظریه الگوریتم ژنتیک زمان بر و بسیار پیچیده هستند، ثانیاً در طراحی معماری شبکه عصبی، اثر متقابل بین عوامل طراحی را در نظر نمی‌گیرند. به همین دلیل نمی‌توان ساختار حاصل از آنها را بهینه دانست.

1. Taguchi method

2. LVQ Net: Learning Vector Quantization Net

3. SOM Net: Self Organizing Map Net

4. Canonical Decomposition Technique

5. Network Information Criterion

6. Polynomial TimeAlgorithm

در این تحقیق به منظور در نظر گرفتن آثار متقابل بین عوامل مختلف در طراحی معماری شبکه عصبی، مدلی با استفاده از تکنیک طراحی آزمایشها^۱ برای شبکه‌های با یادگیری تحت نظارت^۲ ارائه شده است. طی استفاده از این تکنیک از عواملی نظیر نوع شبکه، تعداد لایه‌های پنهان، تعداد نرون‌های هر لایه، توابع پیش‌پردازش و توابع انتقال استفاده می‌شود. در این تحقیق از مدل طراحی شده برای پیش‌بینی مصرف ماهانه نفت‌گاز به عنوان یک مورد استفاده شده است.

در ادامه و در بخش دوم، مدل پیشنهادی تبیین می‌شود. در بخش سوم مدل طراحی شده برای پیش‌بینی مصرف ماهانه نفت‌گاز کل کشور اجرا می‌گردد. در بخش چهارم با استفاده از روش مرسوم در طراحی معماری، یک مدل شبکه عصبی برای پیش‌بینی مصرف نفت‌گاز توسعه داده شده و با شبکه عصبی حاصل از مدل پیشنهادی مورد مقایسه قرار می‌گیرد. همچنین برای مقایسه عملکرد مدل پیش‌بینی مبتتنی بر شبکه عصبی با روش‌های آماری، دو مدل با استفاده از رگرسیون و مدل ARIMA^۳ طراحی و مورد مقایسه قرار گرفته‌اند. در بخش پنجم هم به نتیجه‌گیری پرداخته می‌شود.

۲- مدل پیشنهادی در طراحی معماری

در حقیقت، طراحی معماری شبکه، یک مسأله بهینه‌سازی است که در آن بردار متغیرهای طراحی معماری از قبیل تعداد لایه‌های پنهان و تعداد نرون‌ها در هر لایه، متغیرهای تصمیم‌گیری و شاخصهای اندازه‌گیری خطای شبکه، تابع هدف است.

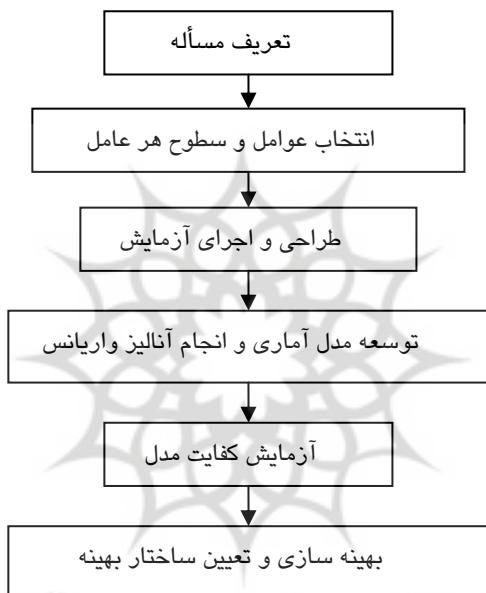
برای حل این‌چنین مسأله بهینه‌سازی از روش‌های رایج نظیر برنامه‌ریزی خطی به سبب ماهیت متغیرهای طراحی و پیچیدگی تابع هدف نمی‌توان استفاده کرد. به همین دلیل در این تحقیق برای بهینه‌سازی مسأله طراحی معماری شبکه عصبی، از مدلی برپایه تکنیک طراحی آزمایشها استفاده می‌شود.

در مدل پیشنهادی، پس از تعریف مسأله موردنظر، عوامل و سطوح هر یک، در طراحی معماری تعیین می‌شود. آنگاه تعدادی آزمایش بر اساس همه ترکیبیهای متفاوت از عوامل و سطوح انجام می‌شود. سپس با انجام آزمون آماری آنالیز واریانس، وجود و یا عدم وجود

1. DOE:Design of Experiment
2. Supervised Learning
3. Taguchi method



تأثیر هریک از عوامل و اثر متقابل بین آنها تعیین می‌شود. پس از آزمایش کفايت مدل^۱، بر اساس نتایج آنالیز واریانس و مشخص شدن آثار معنادار^۲، یک رویه تحت عنوان رویه پاسخ^۳ بر داده‌ها انطباق داده می‌شود. رویه پاسخ، مبنای پیش‌بینی و محاسبه ترکیب بهینه از بین ترکیب‌های متعدد بین عوامل منتخب و سطوح آنها است. در شکل ۱ مدل گام به گام پیشنهادی در طراحی معماری شبکه نشان داده شده است.



شکل ۱ فرایند طراحی آزمایشها

در این تحقیق از مدل پیشنهادی طراحی بهینه معماری شبکه عصبی برای پیش‌بینی مصرف ماهانه نفت‌گاز در کل کشور استفاده می‌شود. به سبب آنکه نفت‌گاز در بخش‌های متنوع اقتصادی کشور استفاده می‌شود، تأمین نابهنجام آن تبعات نامطلوبی دارد. بنابراین باید

1. Model Adequacy
2. Significant Effects
3. Response Surface

به منظور برنامه‌ریزی در تامین فراورده مزبور، مصرف آن به صورت دقیق پیش‌بینی شود.

۱-۲- انتخاب عوامل و سطوح هر عامل

بر طبق شکل ۱ پس از تعریف مسئله و مشخص شدن نوع کاربرد شبکه عصبی، لازم است تا عوامل و سطوح هر یک از آنها در طراحی معماری شبکه عصبی تعیین شود. در این تحقیق، متغیرهای طراحی نوع شبکه، تعداد لایه‌های پنهان، تعداد نرون‌های هر لایه، تابع تبدیل و تابع پیش‌پردازش در نظر گرفته شده‌اند.

۱-۱-۲- نوع شبکه

شبکه پیش‌خوراند، متداولترین شبکه‌ای است که در پیش‌بینی استفاده می‌شود^[۴]؛ صص ۳۰۳-۳۱۰؛ ۲۵]. علاوه بر شبکه‌های پیش‌خوراند، انواع دیگری از شبکه‌های عصبی مصنوعی نیز در پیش‌بینی استفاده شده است. برای مثال، شبکه عصبی بازگشتی^۱ در زمینه الگوهای غیرخطی پویا، جانشین مناسبی برای شبکه پیش‌خوراند در پیش‌بینی سری‌های زمانی است [۲۶، صص ۱۲۵-۱۳۳؛ ۲۷، صص ۳۶-۴۷؛ ۲۸، صص ۷۱-۸۲؛ ۲۹، صص ۲۳۷-۴۲۴-۷۶۵]. در شبکه عصبی بازگشتی، خروجیها می‌توانند به صورت مستقیم، به ورودیها بازخورد بدهند که نتیجه آن بازخورد پویا روى خطای حاصل از الگوهای قبلی است. براین اساس درست مانند مزیتی که مدل‌های ARMA بر AR در پیش‌بینی دارند، پویایی بیشتری نسبت به شبکه‌های پیش‌خوراند دارند. با وجود این، تحقیقات چندانی در بررسی مزیت نسبی شبکه‌های بازگشتی نسبت به شبکه‌های پیش‌خوراند در ادبیات پیش‌بینی صورت نگرفته است. در این تحقیق از دو نوع شبکه عصبی پیش‌خوراند و بازگشتی برای توسعه مدل پیش‌بینی استفاده شده است.

شایان ذکر است در تمام تحقیقات، نوع شبکه در طراحی معماری شبکه عصبی در نظر گرفته نمی‌شود و روش پیشنهادی منحصر به یک نوع شبکه است، اما در این تحقیق با توجه به انعطاف‌پذیری روش پیشنهادی می‌توان این عامل را در زمرة متغیرهای طراحی درنظر گرفت.

1. Recurrent Neural Network



۲-۱-۱- لایه پنهان

نرونهای لایه پنهان شبکه را در کشف الگوی نهفته در داده‌ها و روابط غیرخطی حاکم بر ورودیها و خروجیها، توانند می‌سازند.

در ادبیات موضوع، برخی از محققان تنها از یک لایه پنهان استفاده می‌کنند [۲۳، صص ۳۵-۳۶] و برخی دیگر به استفاده از دو لایه پنهان توصیه می‌نمایند [۳۳، صص ۳۳-۳۴]. Zhang نشان داده است که استفاده از دو لایه پنهان در مسائل پیش‌بینی دقیق و کیفیت پیش‌بینی را ارتقا می‌دهد [۳۵، صص ۱۵۱-۱۷۰]. چنان‌چه در این تحقیق نشان داده می‌شود، استفاده از یک یا دو لایه پنهان به عوامل دیگری بستگی دارد و چنان‌چه Zhang بررسی کرده مستقل از سایر عوامل نمی‌تواند بررسی شود. در این تحقیق از شبکه‌ای با دو لایه پنهان استفاده شده است. برای تعیین تعداد نرونهای لایه پنهان اول، بر مبنای قاعده Hecht و Nielsen از حداکثر $2n+1$ نرون که در آن n تعداد نرونهای لایه ورودی است، عمل شده است [۳۶].

۲-۱-۲- پیش‌پردازش

پیش‌پردازش داده‌ها قبل از آموزش شبکه موجب تسهیل در یادگیری شبکه، فراهم آوردن ملزمات الگوریتم آموزش و اجتناب از پیچیدگی‌های محاسباتی می‌شود [۳۷، صص ۴۲-۴۶؛ ۳۸، صص ۴۱-۴۹]. در ادبیات موضوع بهتابع پیش‌پردازش خاصی اشاره نشده است. لذا در این تحقیق از دوتابع متداول پیش‌پردازش MinMax و انحراف معیار(StdDev) بر اساس رابطه‌های او و بهره‌گیری شده است.

$$X_n = \frac{X - X_{Min}}{X_{Max} - X_{Min}} \quad (1)$$

$$X_n = \frac{X - X_{Mean}}{StdDev} \quad (2)$$

در تابع اول مقادیر ورودی در بازه [۰/۱] به‌طور یکنواخت بر گردانده می‌شود و در تابع دوم، میانگین داده‌ها صفر و انحراف معیار آنها برابر یک می‌شود.

۲-۱-۳- تابع تبدیل

تابع تبدیل، ارتباط بین ورودی و خروجی یک نرون و شبکه را تعیین می‌کند. تابع تبدیل انواع محدودی دارد، اما در پیش‌بینی در اکثر تحقیقات از یک نوع تابع تبدیل در هر لایه و عموماً از توابع لجستیک و هایپربولیک در لایه پنهان و تابع همانی و یا خطی در لایه خروجی استفاده می‌شود[۲۳، صص ۳۵-۳۲]. در این تحقیق از دو نوع تابع تبدیل لجستیک و هایپربولیک در لایه پنهان و از تابع خطی در لایه خروجی استفاده شده است. در جدول ۱، عوامل منتخب در طراحی معماری شبکه عصبی و سطوح هریک به‌طور خلاصه عنوان شده است.

جدول ۱ عوامل و سطوح عوامل مدل طراحی آزمایشها

عامل	(NT)	نوع شبکه	تعداد نرون‌های لایه پنهان اول (N ₁)	تعداد نرون‌های لایه پنهان دوم (N ₂)	تابع پیش‌پردازش (PF)	تابع تبدیل (TF)
سطوح	پیش خوراند	بازگشتی	۱-۱۵	۰,۱,۲	STDV	MinMax

۲-۲- طراحی و اجرای آموزش

در این مرحله، ماتریس آزمایشات شامل تخصیص مناسب عوامل منتخب و سطوح هریک از این عوامل تعیین شده، آنگاه بر اساس ترکیب‌های متفاوت در ماتریس آزمایشات، شبکه طراحی و آموزش داده می‌شود. در این تحقیق براساس جدول ۱، دو سطح برای عامل نوع شبکه، ۱۵ سطح برای تعداد نرون‌های لایه پنهان اول، ۳ سطح برای تعداد نرون‌های لایه پنهان دوم، ۲ سطح برای تابع پیش‌پردازش و ۲ سطح برای تابع تبدیل درنظر گرفته شده است و لذا ماتریس آزمایشات شامل $(2 \times 15 \times 3 \times 2 \times 2) = 360$ ترکیب می‌شود. براساس روش پیشنهادی باید با توجه به تک تک این ترکیبها، شبکه‌های عصبی طراحی شده و با تعدادی تکرار^۱، آموزش داده شوند. در این تحقیق، شبکه عصبی به ازای هر ترکیب، پنج مرتبه آموزش داده

1. Replication



شده است. در شبکه عصبی از الگوریتم‌های آموزش متفاوتی استفاده می‌شود که هر کدام مزایا و معایبی دارند. در این تحقیق، به توصیه Zhang، از الگوریتم لونبرگ_مارکوارت^۱ که از نظر سرعت و اشغال حافظه کمتر، مطلوبیت بیشتری دارد، استفاده شده است[۲۲، صص ۳۵-۶۲].

در گام اول در توسعه مدل آماری باید برای ارزیابی عملکرد، متغیر پاسخ^۲ تعیین شود. محققان از شاخصهای متفاوتی برای ارزیابی عملکرد شبکه عصبی استفاده کردند. از جمله این شاخصها می‌توان به مجموع مربعات خطأ، میانگین مربعات خطأ، میانگین درصد خطأ، میانه درصد خطأ، میانگین انحرافات مطلق^۳ اشاره کرد[۳۹، صص ۵۹۱-۵۹۷]. در این تحقیق از میانگین درصد خطأ به عنوان شاخص ارزیابی عملکرد شبکه عصبی و همچنین متغیر پاسخ در طراحی آزمایشها استفاده شده است.

۳-۲- توسعه مدل آماری و انجام آنالیز واریانس

در این مرحله پس از آموزش شبکه‌های عصبی طراحی شده در مرحله قبل، مدل آماری بسط و توسعه داده می‌شود. برای مثال، مدل آماری یک طرح سه عاملی به شرح رابطه^۴ است.

$$y_{ijkl} = \mu + \tau_i + \beta_j + \gamma_k + (\tau\beta)_{ij} + (\tau\gamma)_{ik} + (\beta\gamma)_{jk} + (\tau\beta\gamma)_{ijk} + \varepsilon_{ijkl} \quad (3)$$

$\left\{ \begin{array}{l} i = 1, 2, \dots, a \\ j = 1, 2, \dots, b \\ k = 1, 2, \dots, c \\ l = 1, 2, \dots, n \end{array} \right.$

که در آن، y_{ijkl} مقدار متغیر پاسخ (در این تحقیق میانگین درصد خطأ) حاصل از مشاهده i, j, k, l میانگین کل، Γ_i تأثیر عامل اول در سطح j ، β_j تأثیر عامل دوم در سطح k ، γ_k تأثیر عامل سوم در سطح l ، $\beta\Gamma_{ij}$ تأثیر متقابل اول و دوم، $\gamma\Gamma_{ik}$ تأثیر متقابل هر سه عامل اول و سوم، $\beta\gamma\Gamma_{ijk}$ تأثیر متقابل عامل دوم و سوم، ε_{ijkl} تأثیر متقابل هر سه عامل، b تعداد

1. Levenberg – Marquardt Algorithm
2. Response variable
3. MSE :Mean Square Error
4. MAPE :Mean Absolute Percentage Error
5. MdAPE :Median Absolute Percentage Error
6. MAD :Mean Absolute Deviation

سطوح عامل دوم، c ، تعداد سطوح عامل سوم، n تعداد تکرار آزمایش^۱ و ϵ_{ijkl} جمله خطأ است. با انجام آنالیز واریانس بر اساس مدل آماری و استفاده از آمار فیشر معنادار بودن هر یک از آثار اصلی و آثار متقابل تعیین می شود [۴۱].

۳-۲-آزمایش کفایت مدل^۲

در این مرحله، برای احراز اطمینان از نتایج حاصل از مدل آماری، دو فرض نرمالبودن باقیماندها^۳ و برابری واریانس‌ها^۴ بررسی می‌شود. برای تعیین فرض نرمال بودن باقیماندها، به طور معمول از آزمون Kolmogorov-Smirnov استفاده می‌شود [۴۱]. برای آزمون فرضیه برابری واریانس‌ها، از آزمون Bartlett استفاده می‌شود. آماره تست Bartlett به شرح رابطه ۴ است.

$$B = \frac{\left(\sum V_i \right) \ln \left(\sum v_i s_i^2 / \sum v_i \right) - \sum v_i \ln s_i^2}{1 + \left\{ \sum (1/v_i) - 1 / \sum v_i \right\} / \{ 3(k-1) \}} \quad (4)$$

که در آن K تعداد نمونه، $v_i = n_i$ تعداد مشاهدات نمونه، $s_i^2 = \sum_{j=1}^{n_i} (x_{ij} - \bar{x})^2 / (n_i - 1)$ است. آماره B دارای توزیع χ^2 با $1 - K$ درجه آزادی است [۴۱].

۳-۲-بهینه‌سازی و تعیین ساختار بهینه

آخرین گام در مدل پیشنهادی، تعیین ساختار بهینه شبکه عصبی مصنوعی است. در این تحقیق، ساختار بهینه از بین ۳۶۰ ترکیب در جدول ۱ انتخاب می‌شود. در طراحی آزمایشها برای تعیین ترکیب بهینه از تکنیک رویه پاسخ استفاده می‌شود. رویه پاسخ، یک رابطه رگرسیونی است که در آن متغیر پاسخ، متغیر وابسته و عوامل طراحی، متغیرهای مستقل هستند. در اکثر مطالعات، رویه پاسخ به صورت یک عبارت ریاضی درجه ۲ کامل^۵ به شرح رابطه ۵ در نظر گرفته می‌شود [۴۱].

-
- 1. Replication
 - 2. Model Adequacy
 - 3. Normality of Residuals
 - 4. Equality of Variances
 - 5. Full Quadratic Equation



$$\hat{Y} = \hat{\beta}_0 + \dots + \hat{\beta}_i x_i + \dots + \hat{\beta}_{ii} x_i^2 + \dots + \hat{\beta}_{ij} x_i x_j + \dots + \hat{\beta}_{iij} x_i^2 x_j + \dots + \hat{\beta}_{ijj} x_i x_j^2 + \dots + \hat{\beta}_{iijj} x_i^2 x_j^2 \quad (2)$$

که در آن x_i سطوح مربوط به آمین عامل طراحی، $\hat{\beta}$ ضرایب مجهول و \hat{Y} مقدار مشاهده شده شاخص خطابه ازای هر ترکیب است. در رابطه \hat{Y} ضرایب مجهول براساس روش کمترین مربعات به دست می آید. پس از تعیین ضرایب مجهول و انطباق یک رویه بر نتایج حاصل از آزمایش، ترکیب بهینه از حل یک مسئله بهینه سازی بدون محدودیت به دست می آید.

۳- اجرای مدل پیشنهادی

تامین و توزیع به موقع نفتگاز، اصلی ترین منبع تأمین کننده انرژی در بخش‌های متعدد اقتصادی کشور از قبیل نیروگاهها، حمل و نقل، صنایع، کشاورزی، کشتیرانی و خانگی اهمیت ویژه‌ای دارد. بروز هرگونه نارسایی در تامین به موقع نفتگاز تبعات اقتصادی، سیاسی و اجتماعی دارد و به همین دلیل باید مصرف آن به صورت دقیق پیش‌بینی شود.

در پیش‌بینی کوتاه‌مدت و بلندمدت تقاضای منابع انرژی از جمله مصرف فراورده‌های نفتی در دهه‌های اخیر تحقیقات زیادی انجام شده و در ذیل آن از مدل‌های متعدد استفاده شده است. Edigar و Akar از روش‌های ARIMA و ARIMA برای پیش‌بینی تقاضای حامله‌ای انرژی در ترکیه طی دوره زمانی ۲۰۰۵ تا ۲۰۲۰، استفاده کردند [۴۲]. Ghosh با استفاده از روش همگرایی و مدل تصحیح خطابه از پیش‌بینی تقاضای فرآورده‌های نفتی هند طی دوره ۲۰۱۲–۲۰۰۱ استفاده کرد. [۴۳، صص ۲۰۳۷–۲۰۳۲]. Pokharel از سیستم معادلات همزمان برای پیش‌بینی مصرف حامله‌ای انرژی در نیال استفاده کرد [۴۴]. Nasr و همکاران، از یک شبکه عصبی بازگشتی برای پیش‌بینی مصرف بنزین استفاده کردند [۴۵، صص ۸۹۳–۹۰۵]. Jebaraj Iniyian و مرور جامعی بر مدل‌های انرژی داشتند [۴۶، صص ۵۶–۶۹]. در این بین از میان انبوه مدل‌های توسعه داده شده، شبکه عصبی نسبت به سایر تکنیک‌ها نظیر اقتصادسنجی، مدل‌های Jenkins و Box و حتی تلفیق این تکنیک‌ها، نوعاً از عملکرد بهتری برخوردار بوده است [۴۶، صص ۵۶–۶۹]. در این تحقیق به دلیل مزایای شبکه عصبی مصنوعی برای پیش‌بینی از شبکه عصبی مصنوعی و برای طراحی معماری شبکه عصبی مربوط به آن از مدل پیشنهادی در طراحی معماری استفاده شد.

داده‌های مسأله از مرکز آمار و اطلاعات شرکت ملی پخش فراورده‌های نفتی به دست آمده و مربوط به مصرف ماهانه نفتگاز طی سالهای ۱۳۷۸ تا سه ماهه سوم ۱۳۸۴ است.

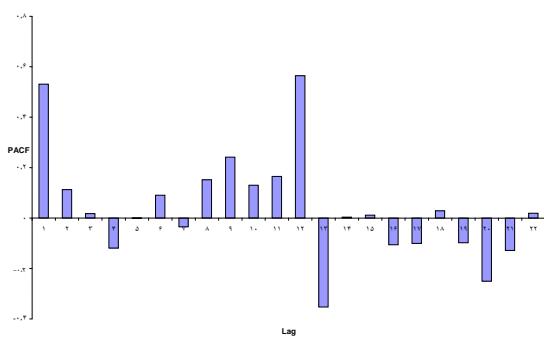
۳-۳- ورودیهای شبکه عصبی

تعیین مجموعه‌ای مناسب از متغیرهای ورودی نقش ویژه‌ای در پیش‌بینی موفق دارد. در پیش‌بینی ماهانه مصرف نفتگاز از دو نوع متغیر ورودی بنیادی شامل متغیر سال به عنوان نمایه‌ای از رشد سالیانه، متغیر فصل به عنوان نمایه‌ای از تغییرات فصلی، متغیر ماه خورشیدی به عنوان نمایه‌ای از مقتضیات رسمی کشور و حداکثر و حداقل دمای هوا در تمامی ایستگاههای سینوپتیک کشور و همچنین مقادیر تأخیر یافته (LAG) استفاده شده است. در این تحقیق برای تعیین تعداد مناسب متغیرهای تأخیر یافته از تابع خود همبستگی جزئی^۱ (PACF) در مدل‌های باکس و جنکینز استفاده شد [۴۸، صص ۳۷۴-۳۸۵]. در شکل‌های ۲ و ۳ نمودار ACF و PACF مربوط به داده‌های مسأله مورد نظر آورده است.



شکل ۲ نمودار ACF برای سری زمانی مصرف ماهانه نفتگاز

1. PACF :Partial Auto Correlation Function



شکل ۳ نمودار PACF برای سری زمانی مصرف ماهانه نفتگاز

براساس شکل‌های ACF و PACF یک موج سینوسی را نشان می‌دهد و PACF بعد از تأخیر ۱ قطع می‌شود. در این صورت می‌توان آنرا AR(1) دانست که تعداد مقادیر تأخیر یافته مناسب برای مدل برابر عدد ۱ می‌شود.

۳-۳-۱- افزای داده‌ها

در مسأله پیش‌بینی به طور معمول داده‌ها به دو مجموعه آموزش و تست تقسیم بندی می‌شوند. از مجموعه داده‌های آموزش برای تعیین مقادیر اوزان شبکه عصبی و از مجموعه داده‌های تست برای ارزیابی توانایی شبکه عصبی و تعیین قابلیت تعمیم آن، استفاده می‌شود. در این تحقیق، در تقسیم‌بندی داده‌ها به دو مجموعه آموزش و تست از نسبت ۸۰ به ۲۰ استفاده شده است [۴۹، صص ۲۲۲-۲۲۸].

۳-۳-۲- طراحی بهینه معماری شبکه عصبی

در مسأله مورد نظر، هدف تعیین معماری بهینه شبکه عصبی به منظور پیش‌بینی مصرف ماهانه نفتگاز است.

۳-۳-۳- تعیین عوامل و سطوح هر یک از عوامل

در این بخش، عوامل و سطوح هریک در طراحی معماری شبکه عصبی تعیین می‌شود. در این تحقیق عوامل طراحی نوع شبکه، الگوریتم آموزش، تعداد لایه‌های پنهان، تعداد نرونهای هر لایه،

تابع تبدیل و تابع پیش-پردازش در نظر گرفته شده‌اند. عوامل ذکر شده و سطوح هریک از این عوامل در جدول ۱ عنوان شده است.

۳-۵-۲- طراحی و اجرای آزمایش

در این مرحله، معماری شبکه‌های عصبی با توجه به تک تک ترکیب‌ها در جدول ۱ طراحی و شبکه حاصل، آموزش داده می‌شود. در این تحقیق، فرایند آموزش به ازای هر ترکیب، ۵ مرتبه اجرا شده است. بنابراین در مجموع $(180 * 5) = 900$ شبکه عصبی ایجاد و آموزش داده شده است. برای آموزش شبکه عصبی از جعبه ابزار شبکه عصبی نرم‌افزار MATLAB و برنامه‌نویسی در محیط MATLAB استفاده شده است. در این تحقیق چنان‌چه بیان شد از میانگین درصد خطای ارزیابی عملکرد شبکه عصبی و همچنین متغیر پاسخ در طراحی آزمایشها استفاده شده است.

۳-۵-۳- توسعه مدل آماری و آنالیز واریانس

در این مرحله پس از آموزش شبکه‌های عصبی و ثبت مشاهدات، مدل آماری توسعه داده شده و آنالیز واریانس انجام می‌شود که نتایج آن در جدول ۲ آورده شده است.

جدول ۲ نتایج آنالیز واریانس

Source	DF	Seq SS	MS	F	P
NT	۱	۵/۷۰E+۲۴	۵/۷۰E+۲۴	۷/۴۶	.۰/۰۰۶
N _۲	۲	۳/۴۲E+۲۵	۱/۷۱E+۲۵	۲۲/۴۶	.۰/۰۰۰
PF	۱	۲/۹۸E+۲۲	۲/۹۸E+۲۲	.۰/۵۲	.۰/۴۷۱
TF	۱	۱/۷۷E+۲۴	۱/۷۷E+۲۴	۲/۳۱	.۰/۰۲۹
N _۱	۹	۲/۲۲E+۲۴	۲/۴۶E+۲۲	.۰/۳۲	.۰/۹۶۸
NT*N _۲	۲	۱/۱۹E+۲۴	۰/۹۳E+۲۲	.۰/۷۸	.۰/۴۶۰
NT*PF	۱	۲/۱۸E+۲۲	۲/۱۸E+۲۲	.۰/۲۹	.۰/۰۹۳
NT*TF	۱	۱/۱۶E+۲۲	۱/۱۶E+۲۲	.۰/۱۵	.۰/۶۹۶
NT*N _۱	۹	۰/۹۵E+۲۴	۰/۱۰E+۲۲	.۰/۸۷	.۰/۰۰۰
N _۲ *PF	۲	۲/۲۲E+۲۲	۱/۱۶E+۲۲	.۰/۱۵	.۰/۸۰۹
N _۲ *TF	۲	۸/۲۰E+۲۴	۴/۱۰E+۲۴	۰/۳۷	.۰/۰۰۰



ادامه جدول ۲

Source	DF	Seq SS	MS	F	P
N _Y *N\	۱۸	۲/۰۴E+۲۰	۱/۱۳E+۲۴	۱/۴۸	./.۰۰۷
PF*TF	۱	۵/۴۴E+۲۲	۵/۴۴E+۲۲	./۷۱	./۳۹۹
PF*N\	۹	۵/۲۱E+۲۴	۵/۷۹E+۲۲	./۷۶	./۰۰
TF*N\	۹	۲/۲۹E+۲۴	۲/۸۶E+۲۲	./۴۸	./۰۰۹
NT*N _Y *PF	۲	۱/۷۵E+۲۴	۸/۷۳E+۲۲	۱/۱۴	./۳۱۹
NT*N _Y *TF	۲	۱/۲۱E+۲۴	۷/۰۴E+۲۲	./۷۹	./۴۰۴
NT*N _Y *N\	۱۸	۱/۲۸E+۲۰	۷/۱۰E+۲۲	./۹۳	./۰۴۱
NT*PF*TF	۱	۸/۰۵E+۲۲	۸/۰۵E+۲۲	./۱۱	./۷۳۸
NT*PF*N\	۹	۷/۲۰E+۲۴	۸/۰۰E+۲۲	۱/۰۵	./۴۰۰
NT*TF*N\	۹	۲/۸۳E+۲۴	۲/۱۰E+۲۲	./۴۱	./۹۲۹
N _Y *PF*TF	۲	۹/۴۶E+۲۲	۴/۷۳E+۲۲	./۶۲	./۰۳۹
N _Y *PF*N\	۱۸	۱/۴۰E+۲۰	۷/۷۸E+۲۲	۱/۰۲	./۴۲۵
N _Y *TF*N\	۱۸	۱/۱۲E+۲۰	۷/۲۲E+۲۲	./۸۱	./۶۸۰
PF*TF*N\	۹	۵/۹۳E+۲۴	۷/۰۹E+۲۲	./۸۶	./۰۵۸
NT*N _Y *PF*TF	۲	۸/۴۶E+۱۹	۴/۲۲E+۱۹	./۷۶	./۰۰
NT*N _Y *PF*N\	۱۸	۹/۰۴E+۲۴	۵/۲۰E+۲۲	./۶۹	./۸۲۰
NT*N _Y *TF*N\	۱۸	۹/۹۴E+۲۴	۵/۰۲E+۲۲	./۷۲	./۷۹۰
NT*PF*TF*N\	۹	۷/۴۹E+۲۴	۷/۲۲E+۲۲	./۹۴	./۴۸۵
N _Y *PF*TF*N\	۱۸	۱/۰۶E+۲۰	۸/۶۴E+۲۲	۱/۱۳	./۳۱۵
NT*N _Y *PF*TF*N\	۱۸	۱/۱۸E+۲۰	۱/۰۱E+۲۴	۱/۲۲	./۱۶۷
Error	۹۶۰	۷/۲۲E+۲۶	۷/۶۴E+۲۲		
Total	۱۱۹۹	۹/۴۰E+۲۶			

براساس مقادیر P-Value در جدول آنالیز واریانس و براساس خطای نوع اول ۵ درصد،

نتایج ذیل استناد می شود.

- نوع شبکه بر عملکرد شبکه مؤثر است.
- تعداد نرونها در لایه پنهان دوم بر عملکرد شبکه مؤثر است.
- تابع تبدیل بر عملکرد شبکه مؤثر است.
- تعداد نرونهای لایه پنهان اول، در کنار سایر عوامل تأثیر کمتری بر عملکرد شبکه دارد.

- تعداد نرونها لایه پنهان اول و لایه پنهان دوم بر هم اثر متقابل دارند. به این معنا که لزوماً، اضافه کردن نرون در هر دو لایه به بهبود عملکرد شبکه منتهی نمی‌شود.
- تعداد نرونها موجود در لایه پنهان دوم و تابع تبدیل بر هم اثر متقابل دارند. به این معنا که اضافه کردن تعداد نرون در کنار یک نوع تابع تبدیل به بهبود عملکرد شبکه منجر شده، در حالی که در کنار تابع تبدیل دیگر موجب تنزل عملکرد شبکه می‌شود.
- تعداد نرونها لایه پنهان اول، اگرچه بر عملکرد شبکه، اثر قابل توجهی ندارد، اما در کنار تابع تبدیل بر عملکرد شبکه مؤثر است و به عبارتی با آن اثر متقابل دارد.
- به همین ترتیب سایر آثار معنادار نیستند.

چنان‌چه مشاهده می‌شود، برخی عوامل، علاوه بر تأثیر بر عملکرد شبکه با سایر عوامل دارای اثر متقابل هستند و در طراحی بهینه شبکه عصبی نمی‌توان آنها را در نظر نگرفت. این در حالی است که Zhang در بررسی میزان تأثیر نرونها و رودی و نرونها لایه پنهان در پیش‌بینی سری‌های زمانی آنها را مستقل از هم در نظر می‌گیرد و از اثر متقابل بین آنها که می‌تواند بر نتایج تأثیرگذار باشد، چشم پوشی می‌کند^[۵]، صص ۳۹۶-۳۸۱.

۴-۵-۳- آزمایش کفایت مدل

برای تعیین فرض نرمال‌بودن باقیماندها بر اساس تست Kolmogorov-Smirnov مقدار آماره KS برابر 0.05 و مقدار P-Value برابر 0.17 می‌شود که با توجه به مقدار P-Value فرض نرمال بودن قابل قبول است.

برای آزمون برابری واریانس‌ها با انجام تست Bartlett مقدار آماره B برابر 0.47 و مقدار P-Value برابر 0.29 می‌شود که مقدار نسبتاً بالای P-Value فرض برابری واریانس‌ها را تأکید می‌کند

۵-۵-۳- تعیین ساختار بهینه

در این مرحله با توجه به آثار معنادار در جدول آنالیز واریانس، یک چندجمله‌ای درجه دو کامل بر داده‌های آزمایش انطباق داده می‌شود و آنگاه با استفاده از بهینه‌سازی غیرخطی بدون محدودیت، جواب بهینه بدست می‌آید. در مسأله تحت بررسی، از آنجا که معادله چندجمله‌ای

1. Unconstrained nonlinear optimization



دارای ۶۶ متغیر است برای رعایت اختصار از ذکر رابطه طولانی آن اجتناب می‌شود. پس از بهینه‌سازی معادله مزبور ساختار بهینه معماری شبکه عصبی که در پیش‌بینی مصرف ماهانه نفتگاز استفاده شده است، بشرح جدول ۳ به دست می‌آید.

جدول ۳ ترکیب بهینه عوامل طراحی معماری شبکه عصبی

ارزش	عامل طراحی
شبکه پیش‌خوراند	نوع شبکه
۸	تعداد نرونها لایه پنهان اول
صفر	تعداد نرونها لایه پنهان دوم
MinMax	تابع پیش‌پردازش
Tansig	تابع تبدیل لایه پنهان

بنابر جدول ۳ معماری شبکه حاصل عبارت است از یک شبکه پیش‌خوراند با یک لایه پنهان و ۸ نرون که در آن از تابع تبدیل Tansig در لایه پنهان و از تابع MinMax برای پیش‌پردازش داده‌ها استفاده شده است.

۳-۳-۱- اجرای مدل پیش‌بینی

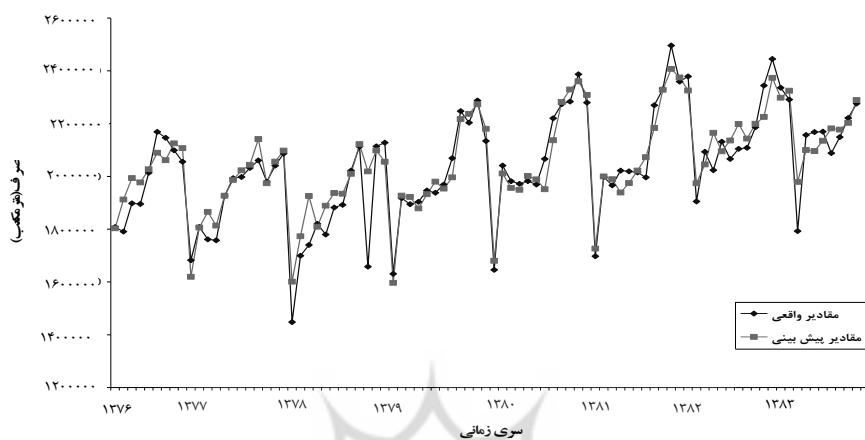
با تنظیم معماری شبکه عصبی براساس جدول ۲ و ایجاد و اجرای شبکه عصبی، نتایج ذیل بر حسب میانگین درصد خطای (MAPE) به دست می‌آید جدول ۴.

جدول ۴ ترکیب بهینه عوامل طراحی معماری شبکه عصبی

MAPE	شرح
%۴,۷	مجموعه آموزش
%۶,۴	مجموعه تست
%۵	مجموعه کل داده‌ها

در شکل ۴ به صورت گرافیکی مقایسه بین پیش‌بینی حاصل از شبکه عصبی و مقادیر

واقعی آمده است.



شکل ۴ نمودار مقایسه بین پیش‌بینی و مقادیر واقعی مصرف ماهانه نفت‌گاز

خطوط پرنگ که با علامت \blacklozenge متمایز شده‌اند، مقادیر واقعی و خطوط کمرنگ که با علامت متمایز شده‌اند مربوط به مقادیر پیش‌بینی است. چنانچه در شکل ۴ مشاهده می‌شود، مقادیر حاصل از پیش‌بینی بر مقادیر واقعی تطبیق سییار خوبی دارند.

۴- مقایسه و ارزیابی

در این بخش، ابتدا عملکرد مدل پیشنهادی در طراحی معماری شبکه عصبی با شبکه‌ای حاصل از رویکرد سعی و خطأ، مقایسه و مزیت آن نشان داده می‌شود. آنگاه دقت و کیفیت پیش‌بینی حاصل از شبکه عصبی، صرف‌نظر از موضوع طراحی معماری شبکه با نوع مدل آماری، یعنی رگرسیون ARIMA مقایسه می‌شود.

۴-۳- مقایسه عملکرد مدل پیشنهادی با دو رویکرد در طراحی معماری

در این بخش برای نشان دادن برتری مدل پیشنهادی به مقایسه عملکرد آن با شبکه عصبی که طراحی معماری آن از روش سعی و خطأ به دست آمده و در غالب تحقیقات استفاده می‌شود، پرداخته می‌شود. در جدول ۴ ساختار شبکه حاصل از استفاده از روش سعی و خطأ و نتایج حاصل از آن براساس



میانگین درصد خطای (MAPE) کل داده‌ها آمده است

جدول ۵ معماری شبکه عصبی با استفاده از روش سعی و خطا

ارزش	عامل طراحی
پیش خوراند	نوع شبکه
۵	تعداد نمونهای لایه پنهان اول
.	تعداد نمونهای لایه پنهان دوم
StDev	تابع پیش‌پردازش
Tansig	تابع تبدیل لایه پنهان
میانگین درصد خطای کل داده‌ها = ۷	
میانگین درصد مجموعه تست = ۱۵/۷ درصد	

بر طبق جدول ۵ و با توجه به میانگین درصد خطای مشاهده می‌شود که استفاده از مدل پیشنهادی، نسبت به روش سعی و خطا دارای مزیت است.

۲-۴- مقایسه با روش‌های آماری

۲-۴-۱- مقایسه با مدل رگرسیون

در مدل رگرسیون مانند شبکه عصبی از متغیرهای سال به عنوان نمایه‌ای از رشد سالیانه، فصل به عنوان نمایه‌ای از تغییرات فصلی، ماه خورشیدی به عنوان نمایه‌ای از مقتضیات رسمی کشور و حداکثر و حداقل دمای هوا در تمامی استگاههای سینوپتیک کشور و مقادیر تأخیریافته (LAG) به عنوان متغیر مستقل و مصروف واقعی به عنوان متغیر وابسته استفاده شده است. بر این اساس مدل رگرسیونی به شرح رابطه ۸ خواهد بود.

$$Y_t = \beta_0 x_{Year,t} + \beta_1 x_{Season,t} + \beta_2 x_{Month,t} \\ + \beta_3 x_{MaxT,t} + \beta_4 x_{MinT,t} + \beta_5 Y_{t-1} + \epsilon_t \quad (3)$$

که در آن $x_{Year,t}$: متغیر سال؛ $x_{Season,t}$: متغیر فصل؛ $x_{Month,t}$: متغیر ماه؛ $x_{MaxT,t}$

حداکثر دمای گزارش شده در کلیه ایستگاههای سینوپتیک کشور، $X_{\text{MinT},t}$: حداقل دمای گزارش شده در کلیه ایستگاههای سینوپتیک کشور: Y_t : مصرف ماه گذشته و ϵ_t : جمله خطای است. در رابطه $(6, i \beta_i = 1)$ ضرایب مجهول است که با روش کمترین مربعات براورد می‌شود. خلاصه نتایج آماری مدل رگرسیون بشرح جدول ۶ است.

جدول ۶ نتایج حاصل از مدل رگرسیون

R Square	.۷۹۸۳۳۶۴۱۴		
Adjusted R Square	.۷۷۵۱۹۴۶۹		
Variable	Coefficients	t Stat	P-value
عرض از مبدأ	-۱۶۶۰۰۱۴	-۲/۶۳۹۱۱۳۳۶۴	.۰۱۰۵۳۶۶۴۲
سال	۳۶۷۸۴/۹	۳/۷۹۱۲۲۱۸۰۳	.۰۰۰۳۴۶۰۸۳
فصل	۶۰۳۹۴/۷	۳/۶۵۸۵۱۲۶۴۹	.۰۰۰۵۳۰۹۱۲
ماه	-۱۰۴۴۵۶/۵	-۱/۸۶۰۵۲۰۲۹۴	.۰۰۷۶۳۲۲۰۸
T_حداکثر	۰/۱۶۶۱۹۲	۱/۵۷۱۵۳۹	.۱۲۱۲۲۱
T_حداقل	۰/۰۶۶۹۰۷	۰/۷۵۱۴۷۱	.۴۰۵۲۰۹
Lag1	۰/۱۰۸۸۰۸	۱/۱۲۱۶۵۸	.۲۶۲۲۰۷

برطبق مقدار R Square در جدول ۷ در عین نیکویی مدل رگرسیونی، اما میانگین درصد خطای (MAPE) آن ۱۷ درصد می‌شود که در مقایسه با میانگین درصد خطای مربوط به کل داده‌ها در مدل شبکه عصبی پیشنهادی از کیفیت پایینتری برخوردار است.

۴-۲-۲- مقایسه با مدل ARIMA

به طور عموم مدل ARIMA(p,q) عبارت است از ترکیب خطی مقادیر و خطاهای گذشته که به صورت رابطه ۷، بیان می‌شود.

$$\begin{aligned} Z_t &= \phi Z_{t-1} + \phi Z_{t-2} + \dots + \phi Z_{t-p} \\ &\quad - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \end{aligned} \quad (7)$$



که در آن $\{\phi_i\}$ و $\{\theta_i\}$ ضرایب مدل و p و q به ترتیب مرتبه اتورگرسیو و میانگین متحرک است. برای تعیین p و q از نمودارهای PACF و ACF استفاده می‌شود. براساس نمودارهای PACF و ACF سری زمانی مصرف نفتگاز و پس از انجام آنالیز آماری، ضرایب مدل سری زمانی و سطوح معنادار بودن هریک از ترمehای اتورگرسیو و میانگین متحرک به شرح جدول ۷ بدست می‌آید.

جدول ۷ نتایج حاصل از تحلیل سری زمانی

Type	Coef	SE Coef	T	P
AR(1)	.۳۹۴۵	.۱۱۴۳	۲/۴۵	.۰۰۱
MA(1)	.۹۲۹۰	.۰۴۱۲	۲۲/۵۳	.۰۰۰

میانگین درصد خطای حاصل از اجرای مدل ARIMA(۱,۱,۱) برابر ۱۲ درصد می‌شود و مشاهده می‌شود در این حالت نیز در مقایسه با میانگین درصد خطای مربوط به کل داده‌ها در مدل شبکه عصبی پیشنهادی از کیفیت پایینتری برخوردار است.

۵- نتیجه‌گیری

یکی از گامهای مهم در توسعه شبکه‌های عصبی مصنوعی طراحی معماری شبکه است که تأثیر بسزایی بر کیفیت عملکرد شبکه دارد. در طراحی معماری شبکه‌های عصبی مصنوعی عواملی از قبیل تعداد لایه‌های پنهان، تعداد نرونها در هر لایه، توابع تبدیل و الگوریتم آموزش باید تعیین شوند. محققان در طراحی معماری شبکه، به طور عمده از طریق سعی و خطا عمل می‌کنند و یا اینکه اثر متقابل بین عوامل مختلف در طراحی معماری شبکه را در نظر نمی‌گیرند. در این تحقیق، یک مدل مبتنی بر تکنیک طراحی آزمایشها برای طراحی بهینه معماری شبکه عصبی با یادگیری هدایت شده ارائه شده است. در مدل پیشنهادی نوع شبکه، تعداد لایه‌های پنهان، تعداد نرونها هر لایه، تابع پیش‌پردازش، تابع تبدیل و اثر متقابل بین عوامل ذکر شده در نظر گرفته شده است. نتایج تجربی این تحقیق نشان می‌دهد که این عوامل علاوه بر تأثیر ثابتی که بر عملکرد شبکه دارند با عوامل دیگر اثر متقابل دارند. این در حالی است که در ادبیات موضوع، اثر متقابل بین عوامل طراحی در نظر گرفته نمی‌شود.

در این تحقیق از مدل پیشنهادی برای طراحی معماری شبکه عصبی به منظور پیش‌بینی مصرف نفتگاز کل کشور استفاده شده است. به منظور مقایسه عملکرد مدل پیشنهادی با استفاده از روش‌های مرسوم در طراحی معماری، یک مدل شبکه عصبی برای پیش‌بینی مصرف نفتگاز توسعه داده شده و طی آن برتری مدل پیشنهادی نشان داده شده است. همچنین برای مقایسه عملکرد شبکه عصبی با روش‌های آماری، دو مدل با استفاده رگرسیون و مدل‌های باکس و جنکیز طراحی شده است. نتایج بدست آمده در پیش‌بینی مصرف نفتگاز در این بخش نشان می‌دهد که پیش‌بینی با شبکه عصبی طراحی شده جوابهای بهتری دارد.

۶- تشکر و قدردانی

شایسته است در این تحقیق به سبب حمایت و در اختیار گذاشتن اطلاعات مربوط به داده‌های مصرف نفتگاز از مدیریت محترم پژوهش و توسعه شرکت ملی پخش فراورده‌های نفتی و همکاران محترم تشکر و قدردانی به عمل آید.

۷- منابع

- [1] Rumelhart D. E., Hinton G. E., Williams R. J.; Learning internal representation by back-propagating errors; MIT Press, 1986.
- [2] Widrow B., Rumelhart D. E., Lehr M. A.; “Neural networks: Applications in industry, business and science”; *Communications of the ACM*, Vol.37, 1994.
- [3] Granger C. W. J., Terasvirta T.; Modeling nonlinear economic relationships; Oxford University Press, 1993.
- [4] Hwaring H.B., “Insights into neural-network forecasting of time series corresponding to ARMA(p,q) structures”; *Omega* 29, 2001.
- [5] Zhang G. P., Patuwo B. E., Hu M. Y.;“ A simulation study of artificial neural networks for nonlinear time-series forecasting”; *Computers & Operations Research*, Vol. 28 , 2001.
- [6] Marquez L.;“Function approximation using neural networks: A simulation study”; Ph.D. Dissertation, University of Hawaii, 1992.
- [7] Ash T.; “Dynamic node creation in backpropagation networks”; *Connection*



Science, Vol.1, 1998.

- [8] Fahlman S.E., Lebiere C.; The cascade-correlation learning architecture; Advances in Neural Information Systems; Morgan-Kaufmann, Los Altos, CA, 1990.
- [9] Kwok T.Y., Yeung D.Y.; "Experimental analysis of input weight freezing in constructive neural networks"; IEEE International Conference on Neural Networks, San Francisco, CA, 1993.
- [10] Islam M. M., Murase, K., " A new algorithm to design compact two-hidden-layer artificial neural networks", Neural Networks, Vol.14, 2001, 1265–1278.
- [11] Miller G.F., Todd P.M., Hedge S. U.; " Designing neural networks using genetic algorithm"; In: Proceedings of the Third International Conference on Genetic Algorithms, 1989.
- [12] Schaffer J. D., Caruana R .A., Eshelman L.J., " Using genetic search to exploit the emergent behavior of neural networks"; Physica D, Vol.42, 1990.
- [13] Arifovic J., Gencay R., "Using genetic algorithms to select architecture of a feedforward artificial neural network"; Physica A, Vol.289, 2001.
- [14] Benardos P.G., Vosniakos G., "Optimization feedforward artificial neural network architecture"; Engineering applications of artificial intelligence, article in press, 2006.
- [15] Kwok T.Y., Yeung D.Y., "Constructive algorithms for structure learning in feedforward neural networks for regression problems"; IEEE Transactions on Neural Networks, Vol.8, 1997.
- [16] Khaw J.F.C., Lim B.S., Lim L.E.N. "Optimal design of neural networks using the Taguchi method"; Neurocomputing, Vol.7, 1995.
- [17] Lin N.H., Chen J.C., "Evaluation of fuzzy-nets training efficiency"; Proceedings of the 1996 Asian Fuzzy Systems Symposium, Taiwan, ROC, 1996.
- [18] Lin T.Y., Tseng C.H.; "Optimal design for artificial neural networks: an example in a bicycle derailleur systems"; Engineering Applications of Artificial Intelligence, Vol.13, No.1, 2000.
- [19] Teo M.Y., Sim S.K., "Training the neocognitron network using design of

- experiment”; Artificial Intelligence in Engineering, Vol.9, No.2, 1995.
- [20] Wang Z., Massimo C. D., Tham M. T., Morris A. J.; “A procedure for determining the topology of multilayer feedforward neural networks”; Neural Networks, Vol.7, No.2, 1994.
- [21] Murata N., Yoshizawa S., Amari S.; “Network information criterion-determining the number of hidden units for an artificial neural network model”; IEEE Transactions on Neural Networks, Vol.5, No.6, 1994.
- [22] Roy A., Kim L. S., Mukhopadhyay S.; “A polynomial time algorithm for the construction and training of a class of multilayer perceptrons”; Neural Networks , Vol.6, 1993.
- [23] Zhang G., Patuwo B.E., Hu M. Y.; “Forecasting with artificial neural networks: The state of the art”; *International Journal of Forecasting* ,Vol.14, 1998.
- [24] Kang, S.; “An Investigation of the Use of Feedforward Neural Networks for Forecasting”; Ph.D. Thesis, Kent State University, 1991.
- [25] Tang Z., Almeida C., Fishwick P. A; “Time series forecasting using neural networks vs Box-Jenkins methodology”; Simulation , Vol.57, No.5, 1991.
- [26] Kermanshahi B.; “Recurrent neural network for forecasting next 10 years loads of nine Japanese utilities”; Neurocomputing, Vol.23, 1998.
- [27] Kuan C.L.; “Forecasting exchange rates using feed forward and recurrent neural network”; *Journal of Applied Econometrics*, Vol.10, 1995.
- [28] Connor J.T., Martin R.D., Atlas L. E.: “Recurrent neural network and robust time series prediction”; IEEE Transaction on Neural Network, Vol.16 ,1994.
- [29] Mediros M.C.P.; “What are the effects of forecasting linear time series with neural network?”; Engineering Intelligent Systems 4, 2001.
- [30] Parrlos A.G., Rais O.T., Atiya A. F.; “Multi step ahead prediction using dynamic recurrent neural network”; *Neural Network* 13, 2000.
- [31] Husken M.S.; “Recurrent neural network for time series classification”; Neurucomputing,Vol.50, 2003.
- [32] Vermark J.B.; “Recurrent neural network for short term load forecasting”;



- IEEE Transaction on Power System, Vol.1, No.13, 1998.
- [33] Barron A.R.; "A comment on Neural networks: A review from a statistical perspective"; *Statistical Science*, Vol.9 , No.1, 1994.
- [34] Srinivasan D., Liew A.C., Chang C. S.; "A neural network short-term load forecaster"; *Electric Power Systems Research*, Vol.28, 1994.
- [35] Zhang X.; "Time series analysis and prediction by neural networks"; *Optimization Methods and Software* 4, 1994.
- [36] Fausett L.; *Fundamentals of Neural Networks*; Prentice-Hall, 1994.
- [37] Lapedes A.,Farber R.; How neural nets work; In: Anderson, D.Z., (Ed.), *Neural Information Processing Systems*, American Institute of Physics, New York, 1988.
- [38] Sharda R., Patil R.B.; "Neural networks as forecasting experts: An empirical test"; In: *Proceedings of the International Joint Conference on Neural Networks*, Washington, D.C.,Vol. 2, 1990.
- [39] Makridakis S., Wheelwright S.C., McGee V. E., *Forecasting: Methods and applications*, 2nd ed, John Wiley, New York, 1983.
- [40] Yokum J.T., Armstrong J. S.; "Beyond accuracy: comparison of criteria used to select forecasting methods"; *International Journal of Forecasting*, Vol.11, 1995.
- [41] Montgomery D. C.; *Design and analysis of experiments*; Wiley, New York, 1991.
- [42] Ediger V. S., Akar S.; "Arima forecasting of primary energy demand by fuel in Turkey"; *Energy Policy*, Article in Press, 2006.
- [43] Ghosh S.; "Future demand of petroleum products in India"; *Energy Policy*, 34, 2006.
- [44] Pokharel S.; "An econometric analysis of energy consumption in Nepal"; *Energy Policy*, Article in Press,2006.
- [45] Nasr G.E., Badr E.A., Joun C.; "Backpropagation neural networks for modeling gasoline consumption"; *Energy Conversion and Management* ,Vol.44, 2003.
- [46] Jebaraj S., Iniyian S.; "A review of energy models, renewable and sustainable energy review";Vol.15, 2004.
- [47] Box G. E., Jenkins G. M.; *Time series analysis: Forecasting and control*; San Francisco, 1976.

- [48] Tang Z., Fishwick P. A.; “Feedforward neural nets as models for time series forecasting”; ORSA *Journal on Computing* . Vol.5, No.4, 1993.
- [49] Granger, C.W. J.; “Strategies for modeling nonlinear time-series relationship”; The Economic Record, Vol.69, 1993.



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرستال جامع علوم انسانی