

ارائه روش ترکیبی طراحی آزمایشات تاگوچی - تاپسیس به منظور یافتن مناسب‌ترین ساختار شبکه‌ی عصبی مصنوعی مورد استفاده در پیش‌بینی تقاضای انرژی^۱ (مطالعه موردی: تقاضای بنزین در استان هرمزگان)

علی مروتی شریف آبادی

Alimorovati_ut@yahoo.com / استادیار دانشکده مدیریت دانشگاه یزد.

رسول خوانچه مهر^۲

Rs_Khanchehmehr@yahoo.com / کارشناس ارشد مدیریت اجرایی دانشگاه یزد.

چکیده

استفاده از شبکه‌های عصبی مصنوعی در پیش‌بینی کاربرد زیادی دارد. طراحی مناسب پارامترهای (ساختار) شبکه موجب می‌شود تا دقت و عملکرد شبکه‌های عصبی مصنوعی افزایش یابد. در اکثر مطالعات از روش سعی و خطا برای تنظیم پارامترهای شبکه‌های عصبی مصنوعی استفاده می‌شود. همچنین، سایر روش‌هایی که برای تعیین بهترین ساختار شبکه عصبی وجود دارد، تنها بر اساس یک معیار ارزیابی عملکرد شبکه، ساختار مناسب را تعیین می‌کنند. در مطالعه حاضر، محققین روش جدیدی را برای طراحی ساختار شبکه ارائه می‌دهند. در این روش، با استفاده از ترکیب روش طراحی آزمایشات تاگوچی و روش تاپسیس، مناسب‌ترین ساختار شبکه‌های عصبی مصنوعی، با در نظر گرفتن سه معیار ارزیابی عملکرد شبکه به طور هم‌زمان، تعیین می‌شود. نتایج حاصل از پیش‌بینی تقاضای بنزین در استان هرمزگان با استفاده از روش مذکور، کارایی و اثربخشی این روش را نشان می‌دهد. تجزیه و تحلیل واریانس پارامترهای شبکه‌های عصبی مصنوعی نشان می‌دهد که سهم مشارکت تعداد نرون در لایه پنهان اول در تعیین ساختار مناسب شبکه حدود ۵۴٪ است و سهم مشارکت الگوریتم یادگیری نیز حدود ۲۷٪ می‌باشد.

طبقه‌بندی JEL: Q30, C45, Q47, C60

کلید واژه: شبکه‌های عصبی مصنوعی، روش طراحی آزمایشات تاگوچی، تاپسیس، دلفی فازی، آنتروپی.

۱- مقاله حاضر از پایان‌نامه رسول خوانچه مهر دانشجوی کارشناسی ارشد مدیریت اجرایی دانشگاه یزد به راهنمایی دکتر علی مروتی شریف آبادی و با عنوان "پیش‌بینی تقاضای فرآورده‌های نفتی با استفاده از شبکه‌های عصبی مصنوعی و روش طراحی آزمایشات تاگوچی (مورد مطالعه: استان هرمزگان)" استخراج شده است.

۲- نویسنده مسئول

۱. مقدمه

امروزه اهمیت پیش‌بینی و منافع حاصل از آن در ابعاد مختلف برای تصمیم‌گیری و سیاست‌گذاری در زمینه‌های مختلف مدیریتی، بر کسی پوشیده نیست. چرا که برنامه‌ریزی بدون داشتن دانش پیش‌بینی امکان‌پذیر نمی‌باشد. به عبارت دیگر، داشتن پیش‌بینی مناسب از آینده، کارایی برنامه‌ریزی را به‌شدت تحت تأثیر قرار می‌دهد (پورکاظمی و اسدی، ۱۳۸۸). از این‌رو، از گذشته و به‌خصوص در چند دهه‌ی اخیر، پیش‌بینی وقایع و درک آینده زمینه‌ی پژوهش‌های زیادی بوده است. برآمد این تلاش‌ها، روش‌های گوناگونی است که بیشتر بر پایه‌ی مدل‌های آماری و اقتصادسنجی بنا شده‌اند. اگرچه روش‌های آماری و اقتصادسنجی، در زمینه پیش‌بینی سری‌های زمانی عملکرد نسبتاً خوبی داشته‌اند، اما در عین حال دارای محدودیت‌هایی نیز هستند (ابریشمی و همکاران، ۱۳۸۹). در تحقیقات اخیر، از شبکه‌های عصبی مصنوعی به‌طور متداول به عنوان ابزار تقریب غیرخطی استفاده شده است و می‌توان با استفاده از آن بر مشکلات و محدودیت‌های روش‌های فوق فائق آمد. (جوادیپور و ناپ^۱، ۲۰۰۳).

طی دهه‌ی گذشته، شبکه عصبی مصنوعی به عنوان ابزاری که الگوی داده‌ها را شناسایی و مدل‌سازی می‌کند، شناخته شده است. تحقیقات مختلف نشان داده‌اند که شبکه‌های عصبی عملکرد بهتری از تکنیک‌های آماری سنتی نظیر رگرسیون چندمتغیره داشته و برای مجموعه‌ای بزرگ و متنوع از مسائل، مناسب می‌باشد (رازی و آتاپیلی^۲، ۲۰۰۵). ANN در پیش‌بینی مسائلی که ناشناخته هستند و فرمول‌های ریاضی و دانش قبلی در رابطه با ورودی‌ها و خروجی‌های آن وجود ندارد، بسیار سودمند هستند. (مورات و سیلان^۳، ۲۰۰۶)

در مطالعات بسیاری و در زمینه‌های زیادی مانند انتخاب تأمین‌کننده (وو^۴، ۲۰۰۹)، پیش‌بینی فروش (لو و همکاران^۵، ۲۰۱۲)، مدیریت درآمد (تسای و چیو^۶، ۲۰۰۹)، پیش‌بینی نسبت‌های مالی شرکت‌ها (مدرکیان و همکاران، ۱۳۹۱)، پیش‌بینی

1 - Javadpour & Knapp

2 - Razi & Athappilly

3 - Murat & Ceylan

4 - Wu

5 - Lu et al

6 - Tsai & Chiou

تقاضای انرژی (پوکک و همکاران^۱، ۲۰۱۳)، و غیره از شبکه‌های عصبی مصنوعی استفاده شده است.

باید توجه شود که یکی از مهم‌ترین موضوعات مرتبط با به‌کارگیری روش شبکه عصبی مصنوعی، طراحی ساختار شبکه می‌باشد. ساختار شبکه باید با توجه به مسأله مورد نظر کاربر ایجاد شود و ساختارهای مختلف شبکه عصبی، پاسخ‌های متفاوتی ارائه می‌کنند. طراحی مناسب ساختار شبکه یا بهینه‌سازی پارامترهای شبکه عصبی مصنوعی (مانند تعداد لایه های مخفی، تعداد نرون در لایه پنهان، الگوریتم آموزش و نرخ یادگیری)، عملکرد و دقت مدل شبکه عصبی را افزایش می‌دهد (آسافا و همکاران^۲، ۲۰۱۳). از آنجایی که طراحی ساختار مناسب شبکه، اهمیت فراوانی دارد، تا کنون محققین از روش‌های مختلفی برای یافتن ساختار مناسب شبکه استفاده کرده‌اند، مانند الگوریتم ژنتیک (میرفخرالدینی و همکاران، ۱۳۹۲)، روش (iSSO^۳) (یه و همکاران^۴، ۲۰۱۴)، تاگوچی (پونتس و همکاران^۵، ۲۰۱۲، یانگ و یام^۶، ۲۰۱۱) و غیره. با این حال، آزمون و خطا شایع‌ترین روش تعیین ساختار شبکه عصبی است (پونتس و همکاران، ۲۰۱۲). اما از آنجا که یافتن بهترین ساختار شبکه بر مبنای آزمون و خطا زمان‌بر است و مهم‌تر این‌که بر مبنای آزمون و خطا هیچ تضمینی در یافتن بهترین ساختار وجود ندارد، محققین در این تحقیق، برای یافتن بهترین ساختار شبکه عصبی از روش طراحی آزمایشات تاگوچی استفاده می‌کنند، زیرا با استفاده از روش طراحی آزمایشات تاگوچی، پارامتر معنی‌داری برای هر عامل و درصد تاثیر عوامل در پاسخ ارائه می‌شود. روش تاگوچی قادر است حالت بهینه‌ای از فرآیند یا شرایط مورد نظر را، تنها بر اساس یک مشخصه‌ی خروجی یا پاسخ تعیین کند. بنابراین، تحقیقاتی که تا کنون به منظور یافتن مناسب‌ترین ساختار شبکه عصبی با استفاده از روش طراحی آزمایشات تاگوچی انجام شده است، نیز مانند سایر روش‌ها (الگوریتم ژنتیک،

1 - Pukec et al

2 - Asafa et al

3 - improved Simplified Swarm Optimization

4 - Yeh et al

5 - Pontes et al

6 - Jung & Yum

(...، تنها بر اساس بهینه‌سازی یک معیار ارزیابی شبکه (مانند MSE^1 ، $MAPE^2$ ، ...) بوده است. به عبارت دیگر، تا کنون محققین با استفاده از روش‌های مختلف، مناسب‌ترین ساختار شبکه را بر اساس بهینه‌سازی تنها یک معیار ارزیابی شبکه‌ی عصبی تعیین کرده‌اند، به عنوان مثال به دنبال ایجاد شبکه‌ای بوده‌اند که کمترین MSE و یا بیشترین R^2 را داشته باشد، و طبق یافته‌های محققین پژوهش حاضر، تا کنون در هیچ تحقیقی روشی برای یافتن ساختار بهینه شبکه عصبی با در نظر گرفتن چندین معیار شبکه به‌طور هم‌زمان، انجام نشده است. اما محققین در پژوهش حاضر، با ترکیب روش طراحی آزمایشات تاگوچی و روش تاپسیس، روشی را ارائه می‌دهند که می‌توان با استفاده از آن، مناسب‌ترین ساختار شبکه عصبی برای مسأله مورد نظر را با در نظر گرفتن و بهینه کردن چندین معیار شبکه به‌طور هم‌زمان، تعیین نمود.

در پژوهش حاضر، محققین به دنبال یافتن بهترین ساختار شبکه عصبی از طریق بهینه کردن سه معیار ارزیابی عملکرد شبکه (MSE ، $MAPE$ ، R^2) می‌باشند. به همین منظور، با استفاده از روش تاپسیس، سه معیار ذکر شده به یک پاسخ تبدیل می‌شوند، سپس با استفاده از روش تاگوچی و بر مبنای پاسخ به‌دست آمده، مناسب‌ترین ساختار شبکه با توجه به مسأله مورد نظر، مشخص می‌شود.

همان‌طور که گفته شد، از ANN برای پیش‌بینی در زمینه‌های مختلف استفاده می‌شود. یکی از مهم‌ترین مواردی که از ANN استفاده می‌شود پیش‌بینی تقاضای انرژی می‌باشد. مدل‌سازی و پیش‌بینی تقاضای انرژی برای سیاست‌گذاران و سازمان‌های مرتبط در کشورهای توسعه یافته و در حال توسعه نقش بسیار مهمی را بازی می‌کند. بی‌توجهی به مصرف، منجر به قطع بالقوه انرژی می‌شود که نابودی زندگی و اقتصاد را در پی دارد. تخمین اضافی انرژی ممکن است منجر به ایجاد ظرفیت بیهوده و غیر ضروری شود که این به معنای اتلاف منابع مالی است (کیالاشاکی و ریسل^۳، ۲۰۱۳). با توجه به مطالعات گذشته، از تحلیل رگرسیون به عنوان پرترفدارترین روش در پیش‌بینی مصرف انرژی استفاده شده است. اما روش شبکه‌های عصبی مصنوعی، برای

1 - Mean Square Error

2 - Mean Absolute Percentage Error

3 - Kialashaki & Reisel

کاربران بالقوه نظیر مهندسين انرژی جذاب تر و دارای اهمیت بیشتری است، زیرا این روش دارای مزیت‌هایی مانند محاسبه سریع، هزینه پایین، قابلیت انجام و طراحی آسان توسط کاربرانی با تجربه فنی کم می‌باشد. بنابراین استفاده از ANN به منظور مدل‌سازی و پیش‌بینی، به‌طور فزاینده‌ای در دهه اخیر مورد توجه قرار گرفته است. (مورات و سیلان، ۲۰۰۶)

از آن جایی که تأمین و توزیع به موقع بنزین، اصلی‌ترین منبع تأمین‌کننده انرژی در بخش حمل و نقل اهمیت ویژه‌ای دارد و بروز هرگونه نارسایی در تأمین به موقع آن تبعات اقتصادی، سیاسی و اجتماعی زیادی را به دنبال دارد و باید تقاضای آن به صورت دقیق و با روش مناسب، پیش‌بینی شود، محققان در تحقیق حاضر با استفاده از ترکیب روش طراحی آزمایشات تاگوچی و روش تاپسیس، مناسب‌ترین ساختار شبکه عصبی به منظور پیش‌بینی تقاضای بنزین استان هرمزگان طی سال‌های ۱۳۹۲-۹۶ را تعیین می‌کنند. بنابراین هدف اصلی تحقیق حاضر، ارائه روش جدیدی برای یافتن مناسب‌ترین ساختار شبکه عصبی و مدل‌سازی و پیش‌بینی تقاضای بنزین در استان هرمزگان و هدف فرعی، تعیین مهم‌ترین عوامل اثرگذار بر عملکرد شبکه‌های عصبی مصنوعی و میزان تأثیر هر یک از عوامل می‌باشد.

مهم‌ترین جنبه نوآوری در این تحقیق، استفاده از روش ترکیبی طراحی آزمایشات تاگوچی - تاپسیس به منظور یافتن مناسب‌ترین ساختار شبکه عصبی می‌باشد. همان‌طور که گفته شد در اکثر تحقیقات از روش سعی و خطا برای تعیین بهترین ساختار شبکه عصبی استفاده شده است. در برخی تحقیقات نیز از روش‌های فراابتکاری مانند الگوریتم ژنتیک استفاده شده است که برتری و مزیت استفاده از روش ترکیبی تاگوچی - تاپسیس نسبت به استفاده از روش‌های پیچیده فراابتکاری، در استفاده از محاسبات کم‌تر، ساده‌تر و سریع‌تر، و علی‌الخصوص بهینه‌سازی هم‌زمان چندین معیار ارزیابی عملکرد شبکه عصبی می‌باشد.

در ادامه، در بخش دوم، پیشینه‌ی پژوهش ارائه می‌شود. بخش سوم، به معرفی شبکه‌های عصبی مصنوعی، روش طراحی آزمایشات تاگوچی و روش تاپسیس می‌پردازد. یافته‌ها و تجزیه و تحلیل نتایج پژوهش در بخش چهارم و بحث و نتیجه‌گیری در بخش

پنجم آورده شده است.

۲. پیشینه پژوهش

روش تاگوچی، یک نوع از تکنیک‌های بهینه‌سازی می‌باشد که در بسیاری از مطالعات برای حل مسائل با متغیرهای طراحی پیوسته، گسسته و کیفی استفاده شده است. بنابراین، می‌توان ساختار بهینه شبکه عصبی را با کمک روش تاگوچی تعیین نمود (لین و تسنگ^۱، ۲۰۰۰). در ادامه، به مطالعاتی که در آن‌ها با استفاده از روش تاگوچی، مناسب‌ترین ساختار شبکه عصبی تعیین شده است، اشاره می‌شود. پس از آن، به تعدادی از مطالعاتی که در زمینه پیش‌بینی تقاضای انرژی با استفاده از شبکه‌های عصبی انجام شده است، پرداخته می‌شود.

کیم و یام^۲ (۲۰۰۴) در تحقیقشان از روش تاگوچی برای یافتن مناسب‌ترین ساختار شبکه عصبی^۳ BPN استفاده کردند و با یک مثال، کارا بودن این روش را نشان دادند. قابل ذکر است که ایشان در تحقیقشان، چهار پارامتر که عبارت بودند از تعداد نرون‌ها در لایه پنهان اول، تعداد نرون‌ها در لایه پنهان دوم، نرخ یادگیری^۴ و مومنتوم^۵، را به عنوان مهم‌ترین پارامترهای اثرگذار بر عملکرد شبکه عصبی و در سه سطح در نظر گرفتند.

وانگ و هیوانگ^۶ (۲۰۰۸) در مطالعه خود به منظور یافتن ساختار بهینه شبکه عصبی با استفاده از روش تاگوچی، شش پارامتر را به عنوان مهم‌ترین پارامترهای اثرگذار بر عملکرد شبکه در نظر گرفتند و سطوح مناسب آن‌ها را تعیین نمودند. این شش پارامتر عبارتند از: تعداد لایه‌های پنهان، تعداد نرون‌ها در لایه پنهان اول، تعداد نرون‌ها در لایه پنهان دوم، فاکتور ارزش وزن‌های اولیه^۷، نرخ یادگیری و مومنتوم. هم‌چنین، سیه و همکاران^۸ (۲۰۱۱) برای افزایش دقت پیش‌بینی تغییرات قیمت

1 - Lin & Tseng

2 - Kim & Yum

3 - BackPropagation Net

4 - learning rate

5 - momentum

6 - Wang & Huang

7 - Initial weight values factor

8 - Hsieh et al

سهام، از روش تاگوچی برای تعیین بهترین ساختار شبکه عصبی بهره بردند. آن‌ها به تعیین سطح بهینه چهار پارامتر شبکه که عبارتند از تعداد نرون‌ها در لایه پنهان، نرخ یادگیری، تعداد دوره‌ها و مومنتوم، پرداختند. قابل ذکر است که هر پارامتر در سه سطح در نظر گرفته شده بود و معیار ارزیابی شبکه عصبی مقدار RMSE بوده است. نتایج این تحقیق نشان داد که استفاده از روش تاگوچی به منظور یافتن ساختار مناسب شبکه عصبی برای پیش‌بینی تغییرات قیمت سهام، مفید بوده و دقت شبکه افزایش یافته است. آسافا و همکاران (۲۰۱۳) نیز برای یافتن ساختار بهینه شبکه عصبی از روش تاگوچی استفاده نمودند. پارامترهایی که در این تحقیق به عنوان مهم‌ترین پارامترهای شبکه عصبی در نظر گرفته شده و سطح بهینه آن‌ها تعیین شد، عبارتند از تعداد لایه‌های پنهان، تعداد نرون‌ها در لایه‌های پنهان، الگوریتم آموزش^۱ و نرخ یادگیری. در این تحقیق، معیار ارزیابی شبکه عصبی، MSE می‌باشد.

همان‌طور که در بخش قبل گفته شد، در اکثر تحقیقات برای یافتن بهترین ساختار شبکه عصبی از روش سعی و خطا استفاده شده است. با توجه به اهمیت و نقش حامل‌های انرژی از جمله بنزین به عنوان یک کالای استراتژیک و تأثیر آن بر اقتصاد کشور و جهان، ارائه پیش‌بینی‌های مناسب از وضعیت تقاضای این فرآورده نفتی، یکی از چالش‌های مهم علمی در سراسر جهان است. در این راستا، مطالعات متعددی در رابطه با پیش‌بینی متغیرهای مطرح در این زمینه از جمله عرضه، تقاضا و قیمت انجام شده است. با توجه به موضوع پژوهش حاضر، در ادامه برخی از مطالعات انجام شده در زمینه پیش‌بینی تقاضای بنزین و انرژی آورده می‌شود.

منهاج و همکاران (۱۳۸۹) با استفاده از شبکه‌های عصبی مصنوعی و با در نظر گرفتن شاخص‌های اقتصادی و اجتماعی، تقاضای انرژی بخش حمل و نقل کشور در سال‌های ۱۳۸۶ تا ۱۴۰۰ را پیش‌بینی کردند. آن‌ها از شبکه‌های عصبی رو به جلو با ناظر، برای پیش‌بینی و از الگوریتم پس انتشار برای آموزش شبکه‌ها استفاده کردند. نتایج حاصل از پیش‌بینی با این روش در مقایسه با روش رگرسیون چند متغیره، دارای

خطای به مراتب کمتری است، به طوری که درصد میانگین قدرمطلق خطا از ۱۵ درصد به ۶ درصد کاهش یافت. منهای و همکاران در مطالعه مذکور، از روش سعی و خطا برای دستیابی به بهترین ساختار شبکه عصبی استفاده کرده‌اند.

ابریشمی و همکاران (۱۳۸۹) از شبکه عصبی^۱ GMDH، برای پیش‌بینی قیمت بنزین مبتنی بر قواعد، تحلیل تکنیکی، شامل میانگین‌های متحرک کوتاه مدت و بلند مدت، به عنوان ورودی شبکه، طی دوره‌های مختلف بازار، استفاده کردند. در این بررسی نیز پیش‌بینی‌های شبکه عصبی نسبت به روش سری زمانی، از خطای کمتر و دقت بالاتری برخوردار است. هم‌چنین، صادقی و همکاران (۱۳۹۰) با استفاده از شبکه عصبی مصنوعی مبتنی بر انتظارات قیمتی برای داده‌های روزانه، به مدل‌سازی و پیش‌بینی روزانه‌ی قیمت سبد نفت خام اوپک پرداختند و نتایج آن با مقادیر پیش‌بینی شده توسط مدل ARIMA بر اساس معیارهای اندازه‌گیری دقت پیش‌بینی، مقایسه شد. نتایج این تحقیق نشان می‌دهد که شبکه عصبی مورد استفاده، نسبت به مدل ARIMA از قدرت پیش‌بینی بیشتر و بهتری برخوردار است. در این مطالعه نیز، با استفاده از روش سعی و خطا مناسب‌ترین ساختار شبکه عصبی تعیین شده است.

میرفخرالدینی و همکاران (۱۳۹۲) با استفاده از روش ترکیبی شبکه‌های عصبی مصنوعی- الگوریتم ژنتیک به پیش‌بینی تقاضای انرژی ایران پرداخته‌اند. آن‌ها برای پیش‌بینی انرژی از جمعیت، تولید ناخالص داخلی، صادرات و واردات به عنوان ورودی شبکه استفاده کردند. نتایج ارزیابی آن‌ها نشان داد که الگوی ترکیبی شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک، نسبت به مدل‌های شبکه عصبی مصنوعی و رگرسیون چند متغیره دارای بالاترین دقت در پیش‌بینی مصرف انرژی کشور می‌باشد.

سیستم‌های هوشمند، به ویژه شبکه‌های عصبی به دلیل عملکرد موفق در زمینه تشخیص و شناسایی مدل، در بسیاری از مسائل پیش‌بینی، مورد استفاده قرار گرفته‌اند که به طور نمونه می‌توان به مطالعات خارجی انجام گرفته زیر اشاره نمود.

جیم و رپر^۲ (۲۰۰۹) با استفاده از شبکه‌های عصبی مصنوعی تقاضای انرژی در کشور کره جنوبی را برای سال‌های ۲۰۱۸ تا ۲۰۲۳ پیش‌بینی کردند. آن‌ها چهار عامل

1 - Group Method of Data Handling

2 - Geem & Roper

تولید ناخالص ملی، جمعیت، واردات و صادرات را به عنوان عوامل تاثیر گذار بر تقاضای انرژی در نظر گرفتند.

رومبایان و همکاران^۱ (۲۰۱۲) برای پیش‌بینی پتانسیل انرژی خورشیدی در اندونزی از شبکه‌های عصبی مصنوعی از نوع پرسپترون چند لایه و الگوریتم آموزش پس‌انتشار خطا استفاده کردند. آن‌ها در تحقیق‌شان داده‌های جغرافیایی و هواشنجی ۲۵ منطقه را برای آموزش و داده‌های ۵ منطقه را برای تست به کار بردند و با استفاده از روش سعی و خطا ساختار مناسب شبکه عصبی به منظور پیش‌بینی پتانسیل انرژی خورشیدی را مشخص کردند.

آزاده و همکاران^۲ (۲۰۱۳) با استفاده از شبکه‌های عصبی مصنوعی و به کار بردن متغیرهای محیطی و اقتصادی مصرف انرژی تجدید پذیر در ایران را پیش‌بینی کردند. متغیرهای ورودی در مدل آن‌ها عبارتند از: انتشار کربن دی اکسید، انتشار نیتروژن اکسید، انتشار کربن مونو اکسید، قیمت گاز، قیمت نفت و تولید ناخالص داخلی. آن‌ها چندین شبکه پرسپترون چند لایه را با تعداد لایه‌های پنهان و تعداد نرون‌های متفاوت ایجاد کردند و بدین‌گونه با استفاده از روش سعی و خطا، مناسب‌ترین ساختار شبکه عصبی برای پیش‌بینی مصرف انرژی تجدید پذیر را تعیین نمودند. جیم (۲۰۱۱) برای پیش‌بینی تقاضای انرژی در بخش حمل و نقل انرژی در کره جنوبی در سال ۲۰۲۵، از شبکه‌های عصبی مصنوعی استفاده کرد. وی داده‌های تولید ناخالص ملی، جمعیت، قیمت فرآورده‌های نفتی، تعداد وسایل نقلیه و مقدار مسافر جا به جا شده را به عنوان ورودی شبکه‌های عصبی مصنوعی بکار برد. همچنین وی نشان داد که نتایج پیش‌بینی با استفاده از شبکه‌های عصبی مصنوعی از رگرسیون خطی چندگانه دقیق‌تر است.

اکونومو^۳ (۲۰۱۰) برای پیش‌بینی بلند مدت تقاضای انرژی کشور یونان از روش شبکه‌های عصبی مصنوعی از نوع پرسپترون چند لایه استفاده و با استفاده از

1 - Rumbayan et al

2 - Azadeh et al

3 - Ekonomou

روش سعی و خطا، صدها ساختار را ایجاد و بهترین ساختار را انتخاب کرده است. با توجه به پیشینه تحقیق، تا کنون در هیچ پژوهشی به بهینه کردن هم‌زمان بیش از یک معیار ارزیابی عملکرد شبکه عصبی پرداخته نشده است. بنابراین، پژوهش حاضر اولین مطالعه‌ای می‌باشد که روشی را برای بررسی و بهینه کردن هم‌زمان سه معیار ارزیابی شبکه عصبی و تعیین ساختار مناسب شبکه بر اساس سه معیار، ارائه می‌دهد.

۳. مبانی نظری

در این بخش، توضیح مختصری راجع به شبکه‌های عصبی مصنوعی، روش طراحی آزمایشات تاگوچی و روش تاپسیس آورده شده است.

شبکه‌های عصبی مصنوعی. برای شبکه‌های عصبی تعاریف زیادی ارائه شده است. در تعریفی ساده، می‌توان آن را شبکه‌ای از عناصر موازی پردازشگر (نرون، سلول عصبی)، که قابلیت ذخیره‌سازی اطلاعات و پاسخ‌گویی به ورودی‌ها بر اساس یک فرایند یادگیری را دارند، دانست (کرامبیا و همکاران^۱، ۲۰۱۲). اصطلاح شبکه‌های عصبی مصنوعی، خانواده‌ای از مدل‌ها را تشریح می‌کند که بر ویژگی‌های فیزیولوژیک سیستم‌های اعصاب حیوانات و انسان‌ها مبتنی هستند. این شبکه‌ها تا حد زیادی به عنوان جعبه سیاهی دیده شده‌اند که الگوی پیچیده در داده‌ها را مشخص می‌کنند. (هاگان و همکاران، ۱۳۸۸)

شبکه‌های عصبی، همانند رگرسیون، ابزاری برای تقریب توابع و یافتن ارتباط میان متغیرهای مستقل و وابسته است. مهم‌ترین تفاوت میان شبکه‌های عصبی و رویکردهای سنتی آماری، در تقریب توابع آن‌ها است که شبکه‌های عصبی بر خلاف روش‌های سنتی آماری هیچ پیش‌فرضی در مورد توزیع و یا خواص آماری داده‌ها به عمل نمی‌آورند و از این نظر می‌توانند در عمل کارایی زیادی داشته باشند. ضمن آن‌که این شبکه‌ها، در زمره‌ی رویکردهای غیرخطی در تدوین مدل‌ها قرار دارند و از این منظر نیز در مواجهه با داده‌هایی که پیچیده و غیرخطی هستند، با دقت بیشتری می‌توانند آن‌ها را در قالب

یک مدل مشخص بیان کنند. (قدیمی و مشیری، ۱۳۸۱)

در حال حاضر به شبکه‌های عصبی مصنوعی، به دلیل کاربرد گسترده آن‌ها در تحقیقات، پزشکی، مدیریت و مهندسی توجه زیادی می‌شود. شبکه‌های عصبی مصنوعی، هم برای بسیاری از مشکلاتی که با روش‌های سنتی قابل حل نمی‌باشند، و هم برای بسیاری از مشکلاتی که با روش‌های سنتی قابل حل می‌باشند، راه‌حل‌های بهتر و معقول‌تری ارائه می‌دهند. (لین و تسنگ^۱، ۲۰۰۰)

شبکه‌های عصبی انواع مختلفی دارند. در اکثر مطالعات منتشر شده از BPNN^۲، به دلیل دقت یادگیری بالا، الگوریتم آسان یادگیر و سرعت فراخوان زیاد، استفاده شده است (کیم و هونگ^۳، ۲۰۰۴، کیم و همکاران، ۲۰۰۳، هان و همکاران^۴، ۱۹۹۶، چن و هسو^۵، ۲۰۰۷). بنابراین، در تحقیق حاضر نیز، محققین از BPNN استفاده می‌کنند.

باید به این موضوع دقت شود که به منظور موفقیت در انطباق با مسائل دنیای واقعی، باید تعیین مناسب ابعاد زیادی از جمله مدل شبکه، اندازه شبکه، تابع فعالیت، پارامترهای یادگیری و تعداد نمونه‌های آموزشی را مدنظر قرار داد (بت شکن، ۱۳۸۰). راه معمول در تعیین پارامترهای شبکه و در نتیجه طراحی شبکه، روش سعی و خطا می‌باشد. بنابراین، باید روشی آسان و کارا تر برای غلبه بر این مشکل وجود داشته باشد. در سال‌های اخیر، روش تاگوچی به عنوان رویکرد جدیدی که می‌تواند برای حل مشکل بهینه‌سازی در این زمینه به کار برود، معرفی شده است (لین و تسنگ، ۲۰۰۰). به همین دلیل، در تحقیق حاضر از روش تاگوچی برای یافتن بهترین ساختار شبکه عصبی استفاده شده است.

طراحی آزمایشات تاگوچی. طراحی آزمایشات تاگوچی، از جمله شیوه‌های آماری است که ضمن حفظ صحت و دقت قابل قبول در نتایج، قادر است به‌طور چشم‌گیری از تعداد آزمایشات بکاهد. هم‌چنین، این روش قادر است که حالت بهینه‌ای از فرآیند یا

1 - Lin & Tseng
 2 - Back propagation neural network
 3 - Kim & Hong
 4 - Han et al
 5 - Chen & Hsu

شرایط مورد نظر را، با توجه به متغیرهای مورد بررسی، تعیین کند (بارادو و همکاران^۱، ۱۹۹۶). طراحی آزمایشات، علمی است که به واسطه‌ی آن، میزان تأثیرگذاری هر کدام از عوامل موثر بر فرآیند تبدیل ورودی به خروجی، مشخص می‌شود. می‌توان گفت که طراحی آزمایشات به عنوان "ایجاد تغییرات هدفمند در مشخصه‌های ورودی یا عامل‌های یک فرآیند برای مشاهده‌ی تغییرات در مشخصه‌ی خروجی یا پاسخ" تعریف می‌شود و با هدف کاهش تعداد آزمایشات، کاهش زمان و هزینه، حذف عامل‌های غیر ضروری، تعیین متغیرها با بیشترین تأثیر بر فرآیند، درصد اهمیت هر متغیر و تعیین شرایط بهینه انجام می‌شود. طراحی آزمایشات روش‌های گوناگونی دارد که به کار بردن هر یک از این روش‌ها با مجموعه‌ای از مزایا و معایب همراه می‌باشد و محدودیت‌هایی را به دنبال دارد. یکی از بهترین روش‌های طراحی آزمایش، روش تاگوچی است چرا که تاگوچی، رویکردی را برای رسیدن به استواری ارائه می‌دهد و برای تحقق این هدف، از ابزارهایی نظیر آرایه‌های متعامد^۲ که تعداد آزمایشات را کاهش می‌دهد و نسبت سیگنال به نویز (مطلوبیت به بدی کارکرد) $(S/N)^3$ ، که هم‌زمان مناسب‌ترین ترکیب و موثرترین معیار را مشخص می‌سازد، استفاده می‌کند. طراحی استوار یک روش مهندسی بهبود کیفیت است که بهترین فرآیند را برای توسعه‌ی محصول با توجه به نیازمندی‌های مشتری طراحی می‌کند. (چن و چانگ^۴، ۲۰۰۸)

روش تاپسیس. این تکنیک توسط هوانگ و یون در سال ۱۹۸۱، پیشنهاد شد. این روش، یکی از بهترین روش‌های تصمیم‌گیری چندشاخصه است و از آن استفاده بسیاری می‌شود. در این روش m گزینه به وسیله n شاخص، مورد ارزیابی قرار می‌گیرد. اساس این تکنیک بر این مفهوم استوار است که گزینه انتخابی باید کم‌ترین فاصله را با راه حل ایده‌ال مثبت (بهترین راه حل ممکن) و بیشترین فاصله را با راه حل ایده‌ال منفی (بدترین راه حل ممکن) داشته باشد (فرمیهنی فراهانی و همکاران، ۱۳۹۳). هدف این مقاله از به‌کارگیری روش تاپسیس، تبدیل سه پاسخ معیار ارزیابی شبکه عصبی به یک پاسخ برای استفاده در روش تاگوچی می‌باشد.

1 - Barrado et al
2 - Orthogonal Arrays (OA)
3 - Signal / Noise
4 - Chen & Chuang

۴. روش تحقیق

تحقیق حاضر از نظر نوع هدف، کاربردی است، از نظر میزان کنترل متغیرها تحقیق توصیفی و از بعد روش گردآوری داده‌ها، تحقیق میدانی (پیمایشی) و کتابخانه‌ای می‌باشد. برای پوشش مباحث تئوریک تحقیق، از کتب عمومی و تخصصی، مقالات و نشریات تخصصی استفاده شده است. ابتدا با بررسی تحقیقات انجام شده در زمینه پیش‌بینی تقاضای بنزین، عوامل موثر بر تقاضای بنزین استخراج شده و با بررسی جامع ادبیات تحقیق و مصاحبه با خبرگان با به‌کارگیری روش دلفی فازی، شاخص‌های مورد نیاز برای سنجش آن‌ها مشخص می‌شود. پس از شناسایی عوامل تأثیرگذار بر تقاضای بنزین در استان هرمزگان، داده‌های مربوطه جمع‌آوری شده و از داده‌های مذکور به عنوان ورودی و خروجی شبکه عصبی استفاده می‌شود. در انتها با استفاده از روش ترکیبی طراحی آزمایشات تاگوچی - تاپسیس، ساختار بهینه شبکه عصبی بر اساس بهینه‌سازی هم‌زمان سه معیار ارزیابی شبکه، تعیین می‌شود.

۵. یافته‌ها و تجزیه و تحلیل داده‌ها

برای تعیین عوامل موثر بر تقاضای بنزین، علاوه بر مرور پیشینه تحقیق، از روش دلفی فازی نیز استفاده شد. ابتدا با مرور پیشینه پژوهش، شش عامل سطح درآمد، تعداد خودروها، کارایی خودروها، قیمت بنزین، متوسط عمر خودروها و جمعیت به عنوان مهم‌ترین عوامل موثر بر مصرف بنزین شناسایی شدند. سپس پرسش‌نامه‌ای شامل این شش عامل، در اختیار ۲۱ نفر مدیران و خبرگان شرکت ملی پخش فرآورده‌های نفتی ایران قرار گرفت و آن‌ها میزان اهمیت و تأثیر هر یک از عوامل را با طیف پنج‌تایی (از بسیار کم تا بسیار زیاد) مشخص کردند. سپس میانگین فازی پاسخ‌ها در مورد هر یک از عوامل در اختیار پاسخ‌دهندگان به پرسش‌نامه اول، قرار داده شد تا در صورت نیاز نظر خود را اصلاح نمایند. در پرسش‌نامه دوم هرچند تعدادی از خبرگان نسبت به اصلاح نظر خود اقدام نمودند اما محدوده تغییر نظر آن‌ها، تغییر فازی خاصی ایجاد نکرد. بنابراین، میانگین فازی نظرات خبرگان تقریباً به صورت قبل باقی ماند و از آنجایی که اختلاف میانگین دو مرحله ناچیز و به صفر میل می‌کند می‌توان نتیجه

گرفت که در مورد عوامل موثر بر تقاضای بنزین، بین خبرگان مورد نظر اجماع خوبی وجود دارد.

روایی محتوای پرسش‌نامه‌ها بر اساس مبانی نظری، نظرات متخصصین و کارشناسان شرکت ملی پخش فرآورده‌های نفتی مورد تأیید قرار گرفت. برای سنجش پایایی پرسش‌نامه این تحقیق از ضریب آلفای کرونباخ استفاده شد. طبق قاعده تجربی ضریب آلفای کرونباخ باید دست کم ۰/۷ باشد تا بتوان مقیاس مورد بررسی را دارای پایایی به شمار آورد. نتیجه به دست آمده برای پایایی پرسش‌نامه با استفاده از نرم افزار SPSS، نشان می‌دهد که ضریب آلفای کرونباخ پرسش‌نامه خبرگان ۰/۸۰۲ است که در حد قابل قبول می‌باشد.

به منظور رعایت اصل مختصر نویسی، تنها نتیجه نهایی آورده شده است. نتایج رتبه‌بندی مهم‌ترین عوامل اثرگذار بر تقاضای بنزین با استفاده از روش دلفی فازی، از لحاظ اهمیت، در جدول ۱ آورده شده است.

جدول ۱- نتایج رتبه‌بندی مهم‌ترین عوامل اثرگذار بر تقاضای بنزین با استفاده از روش دلفی فازی

رتبه	عامل	میانگین اهمیت
۱	جمعیت	۰/۹۵
۲	تعداد خودرو	۰/۸۹
۳	سطح درآمد	۰/۸۴
۴	متوسط عمر خودرو	۰/۶۶
۵	کارایی خودروها	۰/۵۷
۶	قیمت بنزین	۰/۵۱

منبع: نتایج تحقیق

همان‌طور که از جدول بالا قابل مشاهده می‌باشد، عامل جمعیت نسبت به سایر عوامل دارای اهمیت و اثرگذاری بیشتری بر تقاضای بنزین است و عامل قیمت بنزین نسبت به سایر عوامل دارای اهمیت و اثرگذاری کمتری بر تقاضا می‌باشد.

با توجه به نتایج حاصل شده، مهم‌ترین عوامل موثر بر تقاضای بنزین، جمعیت، تعداد خودرو و سطح درآمد (تولید ناخالص داخلی)، به عنوان ورودی شبکه عصبی انتخاب شده‌اند.

پس از تعیین مهم‌ترین عوامل موثر بر تقاضای بنزین، داده‌های مورد نیاز مربوط به سال‌های ۹۰-۱۳۵۱، با استفاده از مستندات شرکت ملی پخش فرآورده‌های نفتی، وزارت نیرو و بانک مرکزی جمع‌آوری شد.

اصولاً استفاده از داده‌ها به صورت خام، باعث کاهش سرعت و دقت شبکه می‌شود. به منظور جلوگیری از چنین حالتی، و همچنین به منظور یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال‌سازی داده‌ها صورت می‌گیرد. عمل نرمال‌سازی مانع از کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زودهنگام نرون‌ها می‌شود (سلطانی و همکاران، ۱۳۸۹). با استفاده از رابطه زیر، داده‌ها نرمال‌ایز شدند.

$$y = 0.8 \times \frac{X_i - X_{min}}{X_{max} - X_{min}} + 0.1 \quad (1)$$

در رابطه بالا، y مقدار نرمال شده‌ی پارامتر، X_i مقدار واقعی هر پارامتر، X_{max} بیش‌ترین مقدار پارامتر مورد نظر و X_{min} کم‌ترین مقدار پارامتر مورد نظر است. هم‌چنین، با مطالعه ادبیات مربوط به شبکه‌های عصبی مصنوعی، مشخص می‌شود که چندین عامل در طراحی ساختار مناسب شبکه عصبی موثرند.

ایجاد یک شبکه عصبی خوب برای یک کاربرد خاص، بسیار مهم است. چهار پارامتر شبکه‌های عصبی مصنوعی به عنوان مهم‌ترین متغیرهای بهینه‌سازی عملکرد شبکه، شناسایی شده‌اند. این چهار پارامتر عبارتند از: تعداد نرون‌ها در لایه مخفی اول، تعداد نرون‌ها در لایه مخفی دوم (Chen & et al., 2007)، نوع الگوریتم آموزش و نرخ یادگیری. بنابراین، در پژوهش حاضر، با استفاده از روش ترکیبی طراحی آزمایشات تاگوچی - تاپسیس و با توجه به سه معیار ارزیابی شبکه به طور هم‌زمان سطح مناسب چهار پارامتر اصلی شبکه عصبی، و در نتیجه ساختار مناسب شبکه برای پیش‌بینی تقاضای بنزین، تعیین می‌شود.

سطح عامل، مقادیر یا حالاتی است که برای عامل در نظر گرفته می‌شود. سطوح مربوط به تعداد نرون‌ها در لایه‌های پنهان اول و دوم (Chen & et al., 2007) در جدول ۲ و سطوح مربوط به نرخ یادگیری (Jung & Yum, 2011) و الگوریتم آموزش (Asafa & et al., 2013) نیز در جدول ۳ آورده شده است.

جدول ۲- تعداد نرون‌ها در لایه‌های پنهان (تعداد ورودی ها = N ، تعداد خروجی ها = P)

عوامل		سطوح
تعداد نرون‌ها در لایه پنهان اول	تعداد نرون‌ها در لایه پنهان دوم	
$\sqrt{N + P}$	$\frac{N + P}{2}$	سطح یک
$2N + 1$	$2N + 1 + \frac{2N + 1}{3}$	سطح دو
$P * (N + 1)$	$P * (N + 1) + \frac{P * (N + 1)}{3}$	سطح سه

منبع: چن و همکاران (۲۰۰۷)

جدول ۳- سطوح مربوط به عوامل نرخ یادگیری و الگوریتم آموزش

عوامل		سطوح
نرخ یادگیری	الگوریتم آموزش	
۰/۱	Scaled Conjugate Gradient	سطح یک
۰/۲	Levenberg-Marquardt	سطح دو
۰/۳	Bayesian Regularization	سطح سه

منبع: آسافا و همکاران (۲۰۱۳)، یانگ و یام (۲۰۱۱)

با توجه به جدول ۲ و هم‌چنین این‌که در تحقیق حاضر، ورودی‌های شبکه عصبی برای پیش‌بینی تقاضای بنزین، چهار عامل جمعیت، تولید ناخالص داخلی، صادرات و واردات ($N=4$)، و خروجی شبکه میزان مصرف بنزین ($OP=1$) است، سطوح مربوط به دو عامل تعداد نرون‌ها در لایه پنهان اول و دوم شبکه عصبی برای پیش‌بینی تقاضای بنزین، مطابق جدول ۴ می‌باشد.

جدول ۴- سطوح مربوط به تعداد نرون‌ها در لایه پنهان اول و دوم شبکه عصبی برای پیش‌بینی بنزین

عوامل		سطوح
تعداد نرون‌ها در لایه پنهان اول (A)	تعداد نرون‌ها در لایه پنهان دوم (B)	
۲	۳	سطح یک
۹	۱۲	سطح دو
۵	۷	سطح سه

منبع: نتایج تحقیق

در این مرحله، باید آرایه متعامد مناسب با توجه به درجه آزادی کل آزمایش تعیین شود. از آنجایی که در این پژوهش، چهار عامل سه سطحی وجود دارد، درجه آزادی کل آزمایش برابر است با هشت ($4 \times (3-1) = 8$). بنابراین، آرایه متعامد $L_8(3^4)$ انتخاب می‌شود (لی و چانگ^۱، ۲۰۰۳) (Li & Chang, 2003). آرایه متعامد $L_9(3^4)$ در جدول ۵ آورده شده است.

جدول ۵- نمایش آرایه متعامد $L_9(3^4)$ مطابق با تحقیق حاضر

شماره آزمایش (ساختار شبکه)	تعداد نرون‌ها در لایه پنهان اول	تعداد نرون‌ها در لایه پنهان دوم	الگوریتم آموزش	نرخ یادگیری
۱	سطح یک	سطح یک	سطح یک	سطح یک
۲	سطح یک	سطح دو	سطح دو	سطح سه
۳	سطح یک	سطح سه	سطح سه	سطح دو
۴	سطح دو	سطح یک	سطح دو	سطح دو
۵	سطح دو	سطح دو	سطح سه	سطح یک
۶	سطح دو	سطح سه	سطح یک	سطح سه
۷	سطح سه	سطح یک	سطح سه	سطح سه
۸	سطح سه	سطح دو	سطح یک	سطح دو
۹	سطح سه	سطح سه	سطح دو	سطح یک

منبع: نتایج تحقیق

ساختار شبکه‌های عصبی برای پیش‌بینی تقاضای بنزین، مطابق آزمایش‌های طراحی شده در آرایه متعامد آورده شده در جدول ۵، طراحی و اجرا شده است. به عنوان مثال، برای انجام آزمایش ششم آرایه متعامد، شبکه‌عصبی با نه نرون در لایه پنهان اول، هفت نرون در لایه پنهان دوم، الگوریتم آموزش Scaled Conjugate

Gradient و نرخ یادگیری ۰/۳ طراحی و اجرا می‌شود. گفتنی است که داده‌های سال‌های ۸۵-۱۳۵۰ به‌عنوان داده‌های آموزش، و داده‌های ۹۰-۱۳۸۶ به‌عنوان داده‌های تست به‌کار برده شده‌اند. از آنجایی که در تحقیق حاضر، برای سنجش عملکرد شبکه‌های عصبی مصنوعی از سه معیار MSE ، $MAPE$ و R^2 استفاده می‌شود، نتیجه اجرای هر یک از آزمایش‌ها برابر MSE ، $MAPE$ و R^2 حاصل از اجرای شبکه عصبی مطابق با آزمایش مربوطه می‌باشد. قابل ذکر است که هر یک از آزمایش‌ها (ساختارهای شبکه عصبی)، پنج بار انجام شده است. برای تبدیل پاسخ‌های (پنج پاسخ) MSE و $MAPE$ به یک پاسخ واحد، و از آنجایی که هر چه مقدار MSE و $MAPE$ کوچک‌تر باشد، عملکرد شبکه بهتر است و مقدار کوچک‌تر MSE و $MAPE$ مطلوب‌تر است، از رابطه (۲) و برای تبدیل پاسخ‌های (پنج پاسخ) R^2 به یک پاسخ واحد، و از آنجایی که هر چه مقدار R^2 بزرگ‌تر باشد، عملکرد شبکه بهتر است و مقدار بزرگ‌تر R^2 مطلوب‌تر است، از رابطه (۳) استفاده شده است.

$$MSD = \frac{(y_1^2 + y_2^2 + \dots + y_r^2)}{r} \Rightarrow \frac{S}{N} = -10 \log\left(\frac{1}{r} \sum_{i=1}^n y_i^2\right) \quad (2)$$

در رابطه بالا، r تعداد تکرار است.

$$MSD = \frac{\frac{1}{y_1^2} + \frac{1}{y_2^2} + \dots + \frac{1}{y_r^2}}{r} \Rightarrow \frac{S}{N} = -10 \log\left(\frac{\frac{1}{y_1^2} + \frac{1}{y_2^2} + \dots + \frac{1}{y_r^2}}{r}\right) \quad (3)$$

پس از محاسبه $\frac{S}{N}$ ، این نسبت به‌عنوان پاسخ آزمایش موردنظر محسوب می‌شود (زینالی، ۱۳۸۷).

نتایج حاصل از اجرای ساختارهای شبکه عصبی برای پیش‌بینی تقاضای بنزین که مطابق جدول ۵ طراحی شده‌اند و نتایج حاصل از تبدیل مقادیر MSE ، $MAPE$ و R^2 به یک پاسخ و بر اساس رابطه ۲ و ۳، به‌ترتیب در جدول ۶، ۷ و ۸ آورده شده است.



ارائه روش ترکیبی طراحی آزمایشات تاگوچی - تاپسیس به منظور یافتن ...

جدول ۶- نتایج حاصل از اجرای ساختارهای شبکه عصبی برای پیش‌بینی تقاضای بنزین بر حسب

MSE

S/N	\bar{Y}	Y5	Y4	Y3	Y2	Y1	شماره آزمایش
۴۱/۷۳۷	۰/۰۰۸۱	۰/۰۰۶۹	۰/۰۰۸۸	۰/۰۰۷۴	۰/۰۰۹۳	۰/۰۰۸۳	۱
۴۳/۳۳۸	۰/۰۰۶۷	۰/۰۰۷۸	۰/۰۰۶۸	۰/۰۰۵۱	۰/۰۰۷۶	۰/۰۰۶۴	۲
۳۶/۷۷۷	۰/۰۱۴۵	۰/۰۱۴۵	۰/۰۱۳۳	۰/۰۱۳۵	۰/۰۱۵۹	۰/۰۱۵۱	۳
۴۳/۰۶۷	۰/۰۰۷۰	۰/۰۰۶۵	۰/۰۰۷۳	۰/۰۰۷۱	۰/۰۰۸۴	۰/۰۰۵۵	۴
۴۲/۵۶۲	۰/۰۰۷۴	۰/۰۰۶۹	۰/۰۰۸۴	۰/۰۰۷۸	۰/۰۰۶۷	۰/۰۰۷۳	۵
۴۲/۵۰۰	۰/۰۰۸۸	۰/۰۰۸۷	۰/۰۰۸۱	۰/۰۰۷۶	۰/۰۰۸۹	۰/۰۱۰۷	۶
۴۶/۳۷۲	۰/۰۰۷۵	۰/۰۰۷۳	۰/۰۰۸۹	۰/۰۰۷۲	۰/۰۰۶۶	۰/۰۰۷۳	۷
۴۲/۸۰۶	۰/۰۰۴۸	۰/۰۰۵۱	۰/۰۰۵۳	۰/۰۰۳۹	۰/۰۰۴۱	۰/۰۰۵۴	۸
۴۲/۲۴۵	۰/۰۰۷۱	۰/۰۰۵۴	۰/۰۰۷۹	۰/۰۰۸۳	۰/۰۰۶۰	۰/۰۰۸۱	۹

منبع: نتایج تحقیق

جدول ۷- نتایج حاصل از اجرای ساختارهای شبکه عصبی برای پیش‌بینی تقاضای بنزین بر حسب

MAPE

S/N	\bar{Y}	Y5	Y4	Y3	Y2	Y1	شماره آزمایش
۱۱/۲۱۲	۰/۲۷۵۰	۰/۲۶۶۵	۰/۲۷۹۷	۰/۲۷۴۴	۰/۲۸۳۹	۰/۲۷۰۳	۱
۱۲/۲۲۷	۰/۲۴۴۶	۰/۲۴۸۳	۰/۲۳۸۱	۰/۲۵۱۷	۰/۲۴۶۰	۰/۲۳۹۱	۲
۱۰/۶۵۰	۰/۲۹۳۳	۰/۲۹۵۴	۰/۳۰۰۲	۰/۲۸۰۵	۰/۲۹۱۰	۰/۲۹۹۶	۳
۱۱/۷۷۲	۰/۲۵۷۷	۰/۲۵۶۳	۰/۲۶۳۶	۰/۲۴۸۴	۰/۲۶۹۳	۰/۲۵۱۱	۴
۹/۷۶۴	۰/۳۱۴۸	۰/۳۱۳۲	۰/۳۳۶۶	۰/۳۲۴۵	۰/۳۳۷۶	۰/۳۱۱۹	۵
۱۰/۷۳۸	۰/۲۹۰۴	۰/۲۸۳۶	۰/۳۰۲۱	۰/۲۹۰۴	۰/۲۸۴۲	۰/۲۹۱۶	۶
۱۱/۴۷۳	۰/۲۶۶۷	۰/۲۶۳۳	۰/۲۷۲۱	۰/۲۶۵۲	۰/۲۸۰۴	۰/۲۵۲۷	۷
۱۳/۲۷۷	۰/۲۱۶۷	۰/۲۳۲۵	۰/۲۱۱۵	۰/۲۰۷۹	۰/۲۱۳۱	۰/۲۱۸۴	۸
۱۳/۳۷۷	۰/۲۱۴۳	۰/۲۱۷۸	۰/۲۰۳۴	۰/۲۲۰۹	۰/۲۱۷۶	۰/۲۱۱۷	۹

منبع: نتایج تحقیق

جدول ۸- نتایج حاصل از اجرای ساختارهای شبکه عصبی برای پیش‌بینی تقاضای بنزین بر حسب R^2

شماره آزمایش	Y1	Y2	Y3	Y4	Y5	ȳ	S/N
۱	۰/۹۶۱۱	۰/۹۵۳۴	۰/۹۶۲۵	۰/۹۶۸۹	۰/۹۷۰۸	۰/۹۶۳۳	-۰/۳۲۵
۲	۰/۹۷۸۲	۰/۹۷۳۹	۰/۹۷۱۸	۰/۹۷۷۵	۰/۹۷۹۲	۰/۹۷۶۱	-۰/۲۱۰
۳	۰/۹۶۰۱	۰/۹۵۶۹	۰/۹۵۳۹	۰/۹۵۴۹	۰/۹۵۸۲	۰/۹۵۶۸	-۰/۳۸۴
۴	۰/۹۶۹۰	۰/۹۶۸۳	۰/۹۵۹۸	۰/۹۶۷۲	۰/۹۶۷۸	۰/۹۶۶۴	-۰/۲۹۷
۵	۰/۹۵۹۱	۰/۹۶۱۶	۰/۹۶۰۷	۰/۹۷۰۱	۰/۹۵۴۶	۰/۹۶۱۲	-۰/۳۴۴
۶	۰/۹۷۷۳	۰/۹۶۳۵	۰/۹۶۶۸	۰/۹۷۰۹	۰/۹۶۶۹	۰/۹۶۹۱	-۰/۲۷۳
۷	۰/۹۷۴۴	۰/۹۷۱۳	۰/۹۷۳۲	۰/۹۷۷۷	۰/۹۷۵۰	۰/۹۷۴۳	-۰/۲۲۶
۸	۰/۹۸۰۷	۰/۹۸۴۴	۰/۹۷۳۹	۰/۹۷۶۷	۰/۹۷۸۵	۰/۹۷۸۸	-۰/۱۸۶
۹	۰/۹۷۳۴	۰/۹۷۰۹	۰/۹۷۷۳	۰/۹۸۰۱	۰/۹۸۰۱	۰/۹۷۸۴	-۰/۱۹۰

منبع: نتایج تحقیق

تبدیل سه معیار ارزیابی عملکرد شبکه به یک پاسخ

برای تعیین مناسب‌ترین ساختار شبکه بر اساس بهینه‌سازی هم‌زمان سه معیار ارزیابی شبکه و با استفاده از روش تاگوچی، باید نتایج مربوط به سه معیار ارزیابی شبکه به یک پاسخ تبدیل شوند. بدین منظور در تحقیق حاضر از روش تاپسیس استفاده شده است.

ابتدا ماتریس تصمیم‌گیری مطابق جدول زیر تشکیل داده شده است. قابل ذکر است که در ماتریس تصمیم‌گیری، از نسبت S/N مربوط به هر معیار با توجه به نتایج آورده شده در جدول‌های ۶، ۷ و ۸، استفاده می‌شود.

جدول ۹- ماتریس تصمیم‌گیری

معیار ارزیابی گزینه (آزمایش)	MAPE	MSE	R ²
۱	۱۱/۲۱۲	۴۱/۷۳۷	-۰/۳۲۵
۲	۱۲/۲۲۷	۴۳/۳۳۸	-۰/۲۱۰
۳	۱۰/۶۵۰	۳۶/۷۷۷	-۰/۳۸۴
۴	۱۱/۷۷۲	۴۳/۰۶۷	-۰/۲۹۷
۵	۹/۷۶۴	۴۲/۵۶۲	-۰/۳۴۴
۶	۱۰/۷۳۸	۴۲/۵۰۰	-۰/۲۷۳
۷	۱۱/۴۷۳	۴۶/۳۷۲	-۰/۲۲۶
۸	۱۳/۲۷۷	۴۲/۸۰۶	-۰/۱۸۶
۹	۱۳/۳۷۷	۴۲/۲۴۵	-۰/۱۹۰

منبع: نتایج تحقیق

سپس با استفاده از نورم، داده‌های ماتریس تصمیم‌گیری بی‌مقیاس می‌شوند. به این معنی که هر عنصر ماتریس تصمیم‌گیری را بر مجذور مربعات عناصر هر ستون در جدول تصمیم‌گیری تقسیم می‌شوند. نتایج حاصل از مرحله بی‌مقیاس‌سازی در جدول ۱۰ آورده شده است.

سپس، برای بدست آوردن ماتریس بی‌مقیاس موزون، اوزان معیارها باید محاسبه شوند. در تحقیق حاضر به منظور محاسبه اوزان معیارها از روش انتروپی استفاده می‌شود. در تئوری اطلاعات، آنتروپی^۱ معیاری است برای مقدار عدم اطمینان بیان شده توسط توزیع احتمال گسسته (P_i) ، به طوری که عدم اطمینان در صورت پخش بودن توزیع، بیشتر از موردی است توزیع فراوانی متمرکزتر باشد.

^۱ - Entropy

جدول ۱۰- نتایج بی‌مقیاس سازی ماتریس تصمیم‌گیری

معیار ارزیابی گزینه (آزمایش)	MAPE	MSE	R ²
۱	۰/۳۲۰۴	۰/۳۲۸۸	-۰/۳۸۸۵
۲	۰/۳۴۹۴	۰/۳۴۱۴	-۰/۲۵۱۱
۳	۰/۳۰۴۳	۰/۲۸۹۷	-۰/۴۵۸۶
۴	۰/۳۳۶۴	۰/۳۳۹۳	-۰/۳۵۴۹
۵	۰/۲۷۹۰	۰/۳۳۵۳	-۰/۴۱۱۱
۶	۰/۳۰۶۸	۰/۳۲۳۴	-۰/۳۲۶۵
۷	۰/۳۲۷۸	۰/۳۳۴۸	-۰/۲۷۰۲
۸	۰/۳۷۹۴	۰/۳۶۵۳	-۰/۲۲۲۳
۹	۰/۳۸۲۲	۰/۳۳۷۲	-۰/۲۲۷۵

منبع: نتایج تحقیق

ابتدا باید محتوای اطلاعاتی موجود در ماتریس تصمیم، به صورت نرمالایز شده (P_{ij}) طبق رابطه زیر محاسبه شود.

$$p_{ij} = \frac{r_{ij}}{\sum_{i=1}^m r_{ij}} \quad (۴)$$

آنتروپی E_j به صورت زیر محاسبه می‌شود و $K = 1/\ln m$ به عنوان مقدار ثابت مقدار E_j را بین ۰ و ۱ نگه می‌دارد.

$$E_j = -k \sum_{i=1}^m p_{ij} \ln p_{ij} \quad (۵)$$

در ادامه مقدار d_j (درجه انحراف) محاسبه می‌شود که بیان می‌کند شاخص مربوطه (d_j) چه میزان اطلاعات مفید را برای تصمیم‌گیری در اختیار تصمیم‌گیرنده قرار می‌دهد. هر چه مقدار اندازه‌گیری شده شاخصی به هم نزدیک باشند، نشان دهنده آن است که گزینه‌های رقیب از نظر آن شاخص تفاوت چندانی با یکدیگر ندارند. بنابراین، نقش آن شاخص در تصمیم‌گیری به همان اندازه کاهش می‌یابد.

$$d_j = 1 - E_j \quad (۶)$$

سپس مقدار وزن W_j محاسبه می‌شود که در آن بهترین وزن انتخاب می‌شود

(اصغرپور، ۱۳۸۸).

$$W_j = d_j / \sum d_j \quad (7)$$

با استفاده از روابط فوق، وزن معیارها محاسبه شده است. به دلیل رعایت اختصار، فقط نتایج نهایی آورده شده است. این نتایج در جدول زیر قابل مشاهده می‌باشد.

جدول ۱۱- نتایج تعیین وزن معیارهای ارزیابی شبکه

معیار	MAPE	MSE	R ²
وزن	۰/۱۲۷	۰/۰۴۳	۰/۸۳

منبع: نتایج تحقیق

پس از تعیین وزن معیارها، ماتریس بی‌مقیاس موزون محاسبه می‌شود. بدین منظور، ماتریس بی‌مقیاس شده، در ماتریس مربعی که عناصر قطر اصلی آن اوزان معیارها و سایر عناصر آن صفر می‌باشد، ضرب می‌شود. ماتریس بی‌مقیاس موزون (V) در جدول زیر آورده شده است.

جدول ۱۲- ماتریس بی‌مقیاس موزون

گزینه (آزمایش)	معیار ارزیابی	MAPE	MSE	R ²
۱		۰/۰۴۰۶	۰/۰۱۴۱	-۰/۳۲۲۵
۲		۰/۰۴۴۳	۰/۰۱۴۷	-۰/۲۰۸۵
۳		۰/۰۳۸۶	۰/۰۱۲۵	-۰/۳۸۰۸
۴		۰/۰۴۲۷	۰/۰۱۴۶	-۰/۲۹۴۶
۵		۰/۰۳۵۴	۰/۰۱۴۴	-۰/۳۴۱۳
۶		۰/۰۳۸۹	۰/۰۱۳۹	-۰/۲۷۱۱
۷		۰/۰۴۱۶	۰/۰۱۴۴	-۰/۲۲۴۳
۸		۰/۰۴۸۱	۰/۰۱۵۷	-۰/۱۸۴۵
۹		۰/۰۴۸۵	۰/۰۱۴۵	-۰/۱۸۸۸

منبع: نتایج تحقیق

حال، باید فاصله هر گزینه از ایده‌آل مثبت و ایده‌آل منفی محاسبه شود. بدین منظور به ترتیب از رابطه ۸ و ۹ استفاده می‌شود.

$$d_i^+ = \sqrt{\sum_{j=1}^m (v_{ij} - v_j^+)^2}, \forall i \quad (8)$$

$$d_i^- = \sqrt{\sum_{j=1}^m (v_{ij} - v_j^-)^2}, \forall i \quad (9)$$

قابل ذکر است از آنجایی که همواره مقادیر بزرگتر S/N مطلوب‌تر است، بنابراین، مقدار ایده‌آل‌های مثبت و منفی برای این موقعیت تصمیم‌گیری به قرار زیر است.

$$J^+ = [\max V_{j1}, \max V_{j2}, \max V_{j3}]$$

$$J^- = [\min V_{j1}, \min V_{j2}, \min V_{j3}]$$

پس از محاسبه فاصله هر گزینه از ایده‌آل مثبت و ایده‌آل منفی، نوبت به محاسبه فاصله نسبی هر گزینه از راه حل ایده‌آل از طریق رابطه زیر می‌باشد.

$$CL_i = \frac{d_i^-}{d_i^+ + d_i^-} \quad (10)$$

مقادیر CL محاسبه شده مربوط به گزینه‌ها (آزمایشات) در جدول زیر آورده شده است.

جدول ۱۲- نتایج حاصل از محاسبه مقادیر CL مربوط به گزینه‌ها (آزمایشات)

گزینه (آزمایش)	۱	۲	۳	۴	۵	۶	۷	۸	۹
CL	۰/۲۹۷	۰/۸۷۷	۰/۰۱۶	۰/۴۴۰	۰/۲۰۱	۰/۵۵۸	۰/۷۹۵	۰/۹۹۸	۰/۹۷۷

منبع: نتایج تحقیق

بدین‌گونه، با استفاده از روش تاپسیس، مقادیر S/N مربوط به معیارهای ارزیابی به CL تبدیل شدند. به عبارت دیگر، سه مقدار S/N مربوط به سه معیار MAPE، MSE و R² به یک مقدار CL تبدیل شده‌اند و از این به بعد، مبنای محاسبات بعدی، مقدار CL می‌باشد.

تعیین بهترین ساختار شبکه عصبی مصنوعی

برای تعیین بهترین ساختار شبکه عصبی، پس از انجام آزمایشات (اجرای شبکه‌های عصبی) و محاسبه نتیجه آزمایشات (مقادیر MSE، MAPE و R²) و همچنین تبدیل سه پاسخ مربوط به سه معیار ارزیابی به یک پاسخ (CL)، باید سطح بهینه هر

یک از عامل‌ها (پارامترهای شبکه عصبی مصنوعی) مشخص شود. بدین منظور، باید ابتدا اثر اصلی عامل‌ها در هر یک از سطوح محاسبه شود. اثر اصلی هر یک از عامل‌ها (به عنوان مثال عامل A) در سطح L، برابر است با مجموع پاسخ‌ها در آن سطح (مجموع پاسخ آزمایش‌هایی که عامل مورد نظر در آن آزمایش‌ها در سطح L قرار دارد)، تقسیم بر تعداد پاسخ‌ها (تعداد آزمایش‌ها).

اثرات اصلی چهار عامل تعداد نرون‌ها در لایه پنهان اول، تعداد نرون‌ها در لایه پنهان دوم، نوع الگوریتم آموزش و نرخ یادگیری در سطوح مختلف، بر عملکرد شبکه‌های عصبی مصنوعی در پیش‌بینی تقاضای بنزین، در جدول ۱۳ آورده شده است.

جدول ۱۳- اثرات اصلی عوامل بر عملکرد شبکه‌های عصبی در پیش‌بینی تقاضای بنزین

عوامل	اثرات اصلی		
	سطح سه	سطح دو	سطح یک
تعداد نرون‌ها در لایه پنهان اول (A)	۰/۹۲۳	۰/۳۹۹	۰/۳۹۷
تعداد نرون‌ها در لایه پنهان دوم (B)	۰/۵۱۷	۰/۶۹۲	۰/۵۱۱
نوع الگوریتم آموزش (C)	۰/۳۳۷	۰/۷۶۵	۰/۶۱۸
نرخ یادگیری (D)	۰/۷۴۳	۰/۴۸۵	۰/۴۹۲

منبع: نتایج تحقیق

لازم به ذکر است که همواره برای شرایط بهینه، مقدار ماکزیمم CL مورد نظر می‌باشد و از آنجایی که نتایج اعلام شده در جداول بالا، بر حسب CL می‌باشد، بهترین سطح هر یک از عوامل با توجه به محاسبات ارائه شده در جدول ۱۳، به شرح جدول ۱۴ می‌باشد.

جدول ۱۴- سطح بهینه عوامل در ساختار شبکه عصبی برای پیش‌بینی تقاضای بنزین

عوامل	سطح بهینه
تعداد نرون‌ها در لایه پنهان اول (A)	سطح سه (۵ نرون)
تعداد نرون‌ها در لایه پنهان دوم (B)	سطح دو (۱۲ نرون)
نوع الگوریتم آموزش (C)	سطح دو (Levenberg-Marquardt)
نرخ یادگیری (D)	سطح سه (۰/۳)

منبع: نتایج تحقیق

با توجه به جدول ۱۴، بهترین ساختار شبکه عصبی برای پیش‌بینی تقاضای بنزین، ساختاری با ۵ نرون در لایه پنهان اول، ۱۲ نرون در لایه پنهان دوم، الگوریتم آموزش Levenberg-Marquardt و نرخ یادگیری سده‌دهم (۰/۳) می‌باشد.

انجام آزمایش تأییدی. در این مرحله، به منظور تأیید مناسب‌ترین ساختار شبکه تعیین شده به روش ترکیبی تاگوچی-تاپسیس، باید ساختار تعیین شده به این روش، طراحی و اجرا شود و نتایج حاصل از اجرای شبکه با توجه به سه معیار ارزیابی (MSE، MAPE و R^2)، با سایر شبکه‌ها مقایسه شود. بدین منظور، نتایج حاصل از پنج بار اجرای ساختار بهینه شبکه پیش‌بینی شده به روش ترکیبی تاگوچی-تاپسیس در جدول زیر آورده شده است.

جدول ۱۵- نتایج حاصل از اجرای ساختار بهینه‌ی شبکه

	اجرای اول	اجرای دوم	اجرای سوم	اجرای چهارم	اجرای پنجم	S/N
MAPE	۰/۱۸۱۱	۰/۱۹۳۲	۰/۱۷۸۳	۰/۲۰۷۷	۰/۱۸۵۱	۱۴/۴۶۱
MSE	۰/۰۰۳۱	۰/۰۰۲۵	۰/۰۰۲۰	۰/۰۰۲۴	۰/۰۰۳۴	۵۱/۳۴۲
R^2	۰/۹۸۰۲	۰/۹۸۲۳	۰/۹۸۱۲	۰/۹۷۶۲	۰/۹۸۲۷	-۰/۱۷۱

منبع: نتایج تحقیق

در جدول ۱۶، نتایج حاصل از مقایسه عملکرد ساختار بهینه شبکه پیش‌بینی شده به روش ترکیبی تاگوچی-تاپسیس با سایر ساختارها آورده شده است. همان‌طور که از جدول بالا قابل مشاهده است، ساختاری که با استفاده از روش ترکیبی تاگوچی-تاپسیس تعیین شده، بسیار کارا تر از مابقی ساختارها می‌باشد. به عنوان مثال، ساختار بهینه نسبت به ساختار شماره ۷، در سه معیار MAPE، MSE و R^2 ، به ترتیب ۲۶، ۲۱ و ۲۴ درصد بهبود یافته است. نتایج حاصل از مقایسه معیارهای ارزیابی شبکه‌های عصبی مربوط به ساختار بهینه با سایر ساختارها، نشان می‌دهد روش ترکیبی تاگوچی-تاپسیس، روشی مفید و قابل اعتماد در یافتن بهترین ساختار شبکه عصبی و بهینه‌کردن هم‌زمان معیارهای ارزیابی شبکه‌های عصبی می‌باشد.

جدول ۱۶- نتایج مقایسه عملکرد ساختار بهینه شبکه پیش‌بینی شده به روش ترکیبی تاگوچی -

تاپسیس با سایر ساختارها

	ساختار ۱	ساختار بهینه	میزان بهبود (%)	ساختار ۲	ساختار بهینه	میزان بهبود (%)	ساختار ۳	ساختار بهینه	میزان بهبود (%)
MAPE	۱۱/۲۱۲	۱۴/۴۶۱	۲۹	۱۲/۲۲۷	۱۴/۴۶۱	۱۸	۱۰/۶۵۰	۱۴/۴۶۱	۳۶
MSE	۴۱/۷۳۷	۵۱/۳۴۲	۲۳	۴۳/۳۳۸	۵۱/۳۴۲	۱۸	۳۶/۷۷۷	۵۱/۳۴۲	۴۰
R2	-۰/۳۲۵	-۰/۱۷۱	۴۷	-۰/۲۱۰	-۰/۱۷۱	۱۹	-۰/۳۸۴	-۰/۱۷۱	۵۵
	ساختار ۴	ساختار بهینه	میزان بهبود (%)	ساختار ۵	ساختار بهینه	میزان بهبود (%)	ساختار ۶	ساختار بهینه	میزان بهبود (%)
MAPE	۱۱/۷۷۲	۱۴/۴۶۱	۲۳	۹/۷۶۴	۱۴/۴۶۱	۴۸	۱۰/۷۳۸	۱۴/۴۶۱	۳۵
MSE	۴۳/۰۶۷	۵۱/۳۴۲	۱۹	۴۳/۰۶۷	۵۱/۳۴۲	۲۱	۴۲/۵۰۰	۵۱/۳۴۲	۲۵
R2	-۰/۲۹۷	-۰/۱۷۱	۴۲	-۰/۳۴۴	-۰/۱۷۱	۵۰	-۰/۲۷۳	-۰/۱۷۱	۳۷
	ساختار ۷	ساختار بهینه	میزان بهبود (%)	ساختار ۸	ساختار بهینه	میزان بهبود (%)	ساختار ۹	ساختار بهینه	میزان بهبود (%)
MAPE	۱۱/۴۷۳	۱۴/۴۶۱	۲۶	۱۳/۲۷۷	۱۴/۴۶۱	۹	۱۳/۳۷۷	۱۴/۴۶۱	۸
MSE	۴۶/۳۷۲	۵۱/۳۴۲	۲۱	۴۲/۸۰۶	۵۱/۳۴۲	۱۱	۴۲/۲۴۵	۵۱/۳۴۲	۲۰
R2	-۰/۲۲۶	-۰/۱۷۱	۲۴	-۰/۱۸۶	-۰/۱۷۱	۸	-۰/۱۹۰	-۰/۱۷۱	۱۰

منبع: نتایج تحقیق

تعیین میزان تأثیر هر یک از عوامل بر عملکرد شبکه عصبی مصنوعی

برای محاسبه درصد سهم هر عامل (به عنوان مثال عامل A) در میزان پراکندگی کل پاسخ‌ها، باید میزان تغییرات ناشی از عامل A را بر کل تغییرات تقسیم کرد. نتایج حاصل از تجزیه و تحلیل داده‌ها برای تعیین سهم مشارکت هر یک از عوامل در عملکرد شبکه عصبی‌ای که برای پیش‌بینی تقاضای بنزین استفاده می‌شود، در جدول ۱۷ آورده شده است.

جدول ۱۷- سهم مشارکت عوامل در عملکرد شبکه عصبی برای پیش‌بینی تقاضای بنزین

Factors	DOF	Sum of Sqrs (S)	Variance (V)	Pur Sum (S')	Percent P (%)
تعداد نرون‌ها در لایه پنهان اول	۲	۰/۵۵۲	۰/۲۷۶	۰/۵۵۲	۵۳/۶۹۸
تعداد نرون‌ها در لایه پنهان دوم	۲	۰/۰۶۳	۰/۰۳۲	۰/۰۶۳	۶/۱۶۴
نوع الگوریتم آموزش	۲	۰/۲۸۳	۰/۱۴۱	۰/۲۸۳	۲۷/۵۰۴
نرخ یادگیری	۲	۰/۱۳۰	۰/۰۶۵	۰/۱۳۰	۱۲/۶۳۴
Error
Total	۸	۱/۰۲۸			۱۰۰

منبع: نتایج تحقیق

با توجه به نتایج ارائه شده در جدول ۱۷، عامل تعداد نرون‌ها در لایه پنهان اول بیش از سایر عوامل بر عملکرد شبکه عصبی تأثیرگذار است. در حالی که سهم مشارکت عامل تعداد نرون‌ها در لایه پنهان اول در عملکرد شبکه عصبی حدود ۵۴ درصد است، سهم مشارکت عامل تعداد نرون‌ها در لایه پنهان دوم شبکه عصبی حدود ۶ درصد می‌باشد. هم‌چنین، سهم مشارکت عامل نوع الگوریتم آموزش و نرخ یادگیری ترتیب حدود ۲۷/۵ و ۱۲/۶ درصد می‌باشد.

۵. نتیجه‌گیری و پیشنهادات

بدیهی است، انرژی یکی از مولفه‌های تأثیرگذار در تولید ثروت و قدرت در جهان کنونی محسوب می‌شود. اقتصاد جهانی با تمامی پیچیدگی‌های خود اعم از جهانی شدن، وابستگی متقابل، تاکید بر رقابت بی‌وقفه، استفاده از مزیت‌های نسبی و غیره، همچنان وابسته به انرژی و تامین امنیت آن است؛ زیرا انرژی نقطه حرکت و سنگ بنای توسعه اقتصاد جهانی است. از سوی دیگر انرژی، خود یکی از ارکان قدرت محسوب می‌شود چون در جهان امروز، توسعه (که خود وابسته به انرژی است)، می‌تواند تولید قدرت نماید. بر این اساس انرژی کالایی استراتژیک است که تامین و امنیت آن نقشی کانونی در امنیت بین‌الملل و اقتصاد جهانی دارد. با توجه به تحولات اقتصاد جهانی، رقابت شدید کشورهای تازه صنعتی شده آسیا با سایر قدرت‌های اقتصادی جهان و نیاز

روزافزون مجموع این کشورها به انرژی و تامین امنیت آن، به نظر نمی‌رسد در دو دهه آینده نقش انرژی در اقتصاد جهانی کاسته شود. در چنین روندی کشورهای برخوردار از ذخایر عمده انرژی اهمیتی استراتژیک در سیاست بین‌الملل می‌یابند و با تدبیر و بهره‌گیری از فرصت‌ها می‌توانند جایگاه و موقعیت خود را ارتقاء بخشند.

بنابراین، در دهه‌های اخیر، انرژی در کنار سایر عوامل تولید نقش تعیین کننده‌ای در رشد اقتصادی کشورها داشته و اهمیت آن هم‌چنان رو به افزایش است. وابستگی روز افزون به انرژی موجب تعامل این بخش با سایر بخش‌های اقتصادی شده و سرعت در روند رشد و توسعه اقتصادی را وابسته به سطح مصرف انرژی کرده است، بطوریکه در دهه‌های اخیر، رشد اقتصادی جهان و روند صنعتی شدن موجب افزایش تقاضا و مصرف انرژی شده است.

همچنین، تامین امنیت عرضه انرژی در دنیا از مسائل استراتژیک پیش روی تمامی دولت‌ها می‌باشد. در کنار محور مدیریت سمت عرضه انرژی، بخشی که کمتر از آن نامی به میان می‌آید، مدیریت سمت تقاضای انرژی است. امروزه تلاش‌ها درون کشور ما در جهت مدیریت سمت عرضه انرژی بوده و کمتر به مدیریت سمت تقاضای انرژی وجه می‌شود، در حالی که مدیریت تقاضای انرژی و تلاش در جهت استفاده بهینه از انرژی در تمامی کشورهای پیشرفته دنیا از مهم‌ترین عوامل پیشرفت صنعتی پایدار بوده است. بنابراین مسئولان کشور باید تلاش کنند تا با پیش‌بینی هرچه دقیق‌تر مصرف انرژی و برنامه‌ریزی صحیح در هدایت مصرف، پارامترهای عرضه و تقاضای انرژی کشور را به نحو مطلوب کنترل کنند. مدل‌سازی و پیش‌بینی تقاضای انرژی برای سیاست‌گذاران و سازمان‌های مرتبط در کشورهای توسعه یافته و در حال توسعه نقش بسیار مهمی را بازی می‌کند. بی‌توجهی به مصرف، منجر به قطع بالقوه انرژی می‌شود که نابودی زندگی و اقتصاد را در پی دارد. تخمین اضافی انرژی ممکن است منجر به ایجاد ظرفیت بیهوده و غیر ضروری شود که این به معنای اتلاف منابع مالی است. در این صورت به منظور کنترل پارامترهای عرضه و تقاضای انرژی و برنامه‌ریزی صحیح در هدایت مصرف آن باید مصرف انرژی را بصورت دقیق پیش‌بینی نمود.

امروزه در مطالعات زیادی از روش شبکه‌های عصبی مصنوعی استفاده می‌شود.

نکته مهم در به کارگیری این روش، طراحی بهینه ساختار شبکه می‌باشد. روش‌های زیادی برای طراحی بهینه ساختار شبکه وجود دارد، اما در تمام این روش‌ها، برای یافتن مناسب‌ترین ساختار شبکه، تنها از یک معیار ارزیابی شبکه استفاده می‌شود. در تحقیق حاضر، محققین با استفاده از روش ابتکاری که ترکیبی از روش تاگوچی و روش تاپسیس می‌باشد، ساختار مناسب شبکه عصبی را با در نظر گرفتن سه معیار ارزیابی به‌طور هم‌زمان، تعیین می‌کنند.

با توجه به اهمیت پیش‌بینی تقاضای بنزین به عنوان یک موضوع مهم و تأثیرگذار که همواره مورد توجه دولت‌ها بوده است، تمرکز مطالعه حاضر بر یافتن بهترین ساختار شبکه‌ی عصبی مصنوعی با به کارگیری روش ترکیبی طراحی آزمایشات تاگوچی-تاپسیس، به منظور پیش‌بینی تقاضای بنزین می‌باشد. بدین منظور، ابتدا با بررسی مطالعات گذشته در حوزه پیش‌بینی انرژی، مهم‌ترین عوامل اثرگذار بر تقاضای بنزین و مصرف انرژی و همچنین با مطالعه پژوهش‌های مرتبط با حوزه شبکه‌های عصبی مصنوعی، مهم‌ترین پارامترهای اثرگذار بر عملکرد شبکه‌های عصبی شناسایی شدند. سپس داده‌های مربوطه جمع‌آوری و به عنوان ورودی شبکه عصبی مصنوعی در نظر گرفته شده‌اند. در مرحله بعد، با استفاده از روش ترکیبی تاگوچی-تاپسیس، و در نظر گرفتن سه معیار ارزیابی عملکرد شبکه به‌طور هم‌زمان ($MAPE$, MSE , $R2$)، بهترین ساختار شبکه عصبی به منظور پیش‌بینی تقاضای بنزین طراحی شده است. یافته‌های پژوهش نشان می‌دهد که با استفاده از روش تاگوچی-تاپسیس می‌توان بهترین ساختار شبکه عصبی مصنوعی را با توجه به هدف مورد نظر تعیین نمود. همان‌طور که گفته شد، در اکثر مطالعات از روش سعی و خطا برای تنظیم پارامترهای شبکه‌های عصبی مصنوعی استفاده می‌شود. روش سعی و خطا برای رسیدن به مناسب‌ترین ساختار شبکه‌های عصبی مصنوعی راه حل مطمئنی نمی‌باشد. نتایج تحقیق حاضر نشان می‌دهد که استفاده از روش تاگوچی-تاپسیس راهی مناسب برای تعیین بهترین ساختار و تنظیم پارامترهای شبکه‌های عصبی مصنوعی می‌باشد و کارایی و دقت شبکه‌های طراحی شده با روش مذکور، بیشتر از سایر شبکه‌ها می‌باشد.

فهرست منابع

- ابریشمی، حمید، معینی، علی، مهرآرا، محسن، احراری، مهدی و سلیمانی کیا، فاطمه (۱۳۸۷). مدل سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه عصبی GMDH. پژوهشهای اقتصادی ایران، شماره ۳۶.
- اصغر پور؛ محمد جواد، (۱۳۸۸)، تصمیم‌گیری‌های چندمعیاره، چاپ هفتم، انتشارات دانشگاه تهران.
- بت شکن، محمود (۱۳۸۰). پیش‌بینی قیمت سهام با استفاده از شبکه‌های عصبی - فازی و مقایسه آن با الگوهای خطی پیش‌بینی. پایان‌نامه کارشناسی ارشد، دانشگاه تهران.
- پورکاظمی؛ محمد حسین، اسدی؛ محمد باقر (۱۳۸۸). پیش‌بینی پویای قیمت نفت خام با استفاده از شبکه‌های عصبی مصنوعی و با به کارگیری ذخیره‌سازی‌های نفتی کشورهای OECD. *مجله تحقیقات اقتصادی*. شماره ۸۸، صص ۲۵-۴۶.
- زینالی؛ الهام (۱۳۸۷). طراحی آزمایش به روش تاگوچی با استفاده از نرم افزار Qualitek. نشر شرکت پژوهش و فناوری پتروشیمی.
- سلطانی؛ سعید، سرداری؛ سروش، شیخ‌پور؛ مژگان، موسوی؛ صغری (۱۳۸۹). شبکه‌های عصبی مصنوعی: مبانی، کاربردها و آشنایی با نرم‌افزارهای Easy NN-Plus و NeuroSolutions. انتشارات نص، تهران.
- صادقی؛ حسین، ذوالفقاری؛ مهدی، الهامی‌نژاد؛ مجتبی (۱۳۹۰). مقایسه عملکرد شبکه‌های عصبی و مدل ARIMA در مدل‌سازی و پیش‌بینی کوتاه مدت قیمت سبده نفت خام اوپک (با تأکید بر انتظارات تطبیقی). *فصلنامه مطالعات اقتصاد انرژی*. سال هشتم، شماره ۲۸، صص ۲۵-۴۷.
- فرمیپنی فراهانی؛ محسن، ملکی؛ مهدی؛ فاضل‌علاف؛ علی، (۱۳۹۳)، شناسایی و اولویت‌بندی صلاحیت‌های اثر بخش مدرسان از دید دانشجویان با استفاده از روش‌های ای اچ پی و تاپسیس، پژوهش در برنامه‌ریزی درسی، سال یازدهم، دوره دوم، شماره سیزده (پیاپی ۴۰)، صفحات ۸۰-۹۲.
- قدیمی؛ محمدرضا، مشیری؛ سعید (۱۳۸۱). مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی (ANN). *فصلنامه پژوهش‌های اقتصادی ایران*. شماره ۱۲، صص ۱-۳۳.
- مدرکیان، حسن؛ موحدی، محمد مهدی؛ طیبی راد، وحیده؛ طیبی راد، محمد (۱۳۹۱)،

پیش‌بینی نسبت‌های مالی با استفاده از شبکه‌های عصبی مصنوعی در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، فصلنامه مدیریت، سال نهم، ویژه نامه، ۶۵-۷۵.
 منہاج؛ محمد باقر، کاظمی؛ عالیہ، شکوری گنجوی؛ حامد، مهرگان؛ محمدرضا، تقی زاده؛ محمدرضا (۱۳۸۹). پیش‌بینی تقاضای انرژی بخش حمل و نقل با استفاده از شبکه‌های عصبی: مطالعه موردی در ایران. *مجله مدرس علوم انسانی*. دوره چهاردهم، شماره ۲، صص ۲۲۰-۲۰۴.

میرفخرالدینی؛ سید حیدر، بابایی میبیدی؛ حمید، مروتی شریف آبادی؛ علی (۱۳۹۲). پیش‌بینی مصرف انرژی ایران با استفاده از مدل ترکیبی الگوریتم ژنتیک- شبکه عصبی مصنوعی و مقایسه آن با الگوهای سنتی. *پژوهش‌های مدیریت در ایران*. دوره ۱۷، شماره ۲، صفحه ۱۹۷-۲۲۲.

هاگان، مارتین تی، دیموث، هاروارد بی و بیل، مارک (۱۳۸۸). طراحی شبکه‌های عصبی. ترجمه: سید مصطفی کیا. انتشارات کیان رایانه سبز، تهران.

- Asafa T.B., Tabet N. & Said S.A.M. (2013). Taguchi method-ANN integration for predictive model of intrinsic stress in hydrogenated amorphous silicon film deposited by plasma enhanced chemical vapour deposition. *Neurocomputing*, 106, 86-94.
- Azadeh, A., Babazadeh, R. & Asadzadeh, S.M. (2013). Optimum estimation and forecasting of renewable energy consumption by artificial neural networks. *Renewable and Sustainable Energy Reviews*, 27, pp: 605 – 612.
- Barrado, E., Vega, M., Pardo, R., Grande, P. & Del Valle J.L. (1996). Optimization of a purification method for metal-containing wastewater by use of a Taguchi experimental design. *Wat. Res.* 30(10), 2309-2314.
- Chen, C. & Chuang M. (2008). Integrating the Kano model into robust design approach to enhance customer satisfaction with product design. *International journal of production economics*, 114, pp 667-681.
- Chen, W.C., Lee, A.H., Deng, W.J. & Liu, K.Y. (2007). The implementation of neural network for semiconductor PECVD process. *Expert Syst. Appl.* 32, 1148-1153.
- Ekonomou, L. (2010). Greek long-term energy consumption prediction using artificial neural networks. *Energy*, 35, pp: 512-517 .
- Geem, Z.W. (2011). Transport energy demand modeling of South Korea using artificial neural network. *Energy Policy*, 39, 4644-4650.
- Geem, Z.W. & Roper, WE. (2009). Energy demand estimation of South Korea using artificial neural network. *Energy Policy*, Vol 37, pp: 4049:4054.
- Javadpour, R. & Knapp, GM. (2003). A fuzzy neural network approach to

- machine condition monitoring. *J Computers And industrial engineering*, Vol 45, pp: 323-330.
- Jung, J. & Yum B. (2011). Artificial neural network based approach for dynamic parameter design. *Expert Systems with Applications*, 38, 504–510.
- Kialashaki, A. & Reisel, J.R. (2013). Modeling of the energy demand of the residential sector in the United States using regression models and artificial neural networks. *Applied Energy*, 108, pp: 271–280.
- Krambia-Kapardis, M., Christodoulou, C. & Agathocleous, M. (2010). Neural networks: the panacea in fraud detection?. *Managerial Auditing Journal*, 7, 659-678.
- Li, Z.C. & Chang, D.Y. (2003). Tool wear investigation on the precision progressive die for the IC dam-bar cutting process. *Int. J. Adv. Manuf. Technol.* 22, 344–356.
- Murat, YS. & Ceylan, H. (2006). use of artificial neural networks for transport energy demand modeling. *Energy Polisy*, vol. 34, pp: 3165-3172.
- Pontes, F. J., de Paiva, A. P., Balestrassi, P. P., Ferreira, J. R. & da Silva, M. B. (2012). Optimization of Radial Basis Function neural network employed for prediction of surface roughness in hard turning process using Taguchi's orthogonal arrays. *Expert Systems with Applications*, 39, 7776–7787.
- Razi, M.A. & Athappilly, K. (2005). A Comparative Predictive analysis of neural networks (NNs), nonlinear regression and classification and regression tree (CART) models. *Expert System with Applications*, 29, 65-74.
- Rumbayan, M., Abudureyimu, A. & Nagasaka, K. (2012). Mapping of solar energy potential in Indonesia using artificial neural network and geographical information system. *Renewable and Sustainable Energy Reviews*, 16 ,pp: 1437– 1449.
- Wu, Desheng (2009). Supplier selection: A hybrid model using DEA, decision tree and neural network. *Expert Systems with Applications*, 36, 9105–9112.
- Chi-Jie Lu, Tian-Shyug Lee, Chia-Mei Lian. (2012). Sales forecasting for computer wholesalers: A comparison of multivariate adaptive regression splines and artificial neural networks, *Decision Support Systems*, 54, 584 – 596.
- Chih-Fong Tsai, Yen-Jiun Chiou (2009), Earnings management prediction: A pilot study of combining neural networks and decision trees, *Expert Systems with Applications*, 36, 7183–7191.

- Tomislav Pukey, Goran Krajacic, Zoran Lulic, Brian Vad Mathiesen, Neven Duic (2013), Forecasting long-term energy demand of Croatian transport sector, *Energy*, 57, 169-176.
- Wei-Chang Yeh, Yuan-Ming Yeh, Po-Chun Chang, Yun-Chin Ke, Vera Chung, (2014), Forecasting wind power in the Mai Liao Wind Farm based on the multi-layer perceptron artificial neural network model with improved simplified swarm optimization, *Electrical Power and Energy Systems*, 55, 741-748.
- Lin, T.Y., Tseng, C.H., (2000), Optimum design for artificial neural networks: an example in a bicycle derailleur system, *Engineering Applications of Artificial Intelligence*, 13, 3-14.
- Young-Sang Kim, Bong-Jin Yum (2004), Robust design of multilayer feedforward neural networks: an experimental approach, *Engineering Applications of Artificial Intelligence*, 17, 249-263.
- Tai-Yue Wang, Chien-Yu Huang, (2008), Optimizing back-propagation networks via a calibrated heuristic algorithm with an orthogonal array, *Expert Systems with Applications*, 34, 1630-1641.
- Ling-Feng Hsieh, Su-Chen Hsieh, Pei-Hao Tai, (2011), Enhanced stock price variation prediction via DOE and BPNN-based optimization, *Expert Systems with Applications*, 38, 14178-14184.
- Kim B., Hong, W.S., Use of neural network to characterize a low pressure temperature effect on refractive property of silicon nitride film deposited by PECVD, *IEEE Trans. Plasma Sci.* 32 (1) (2004) 84-89.
- Kim, B., Kim, D.W., Park, G.T., Prediction of plasma etching using a polynomial neural network, *IEEE Trans. Plasma Neural Network Sci.* 31 (6) (2003) 1330-1336.
- Han, S.L., May, G.S., Rohatgi, A., Modeling the growth of PECVD silicon nitride films for solar cell applications using neural networks, *IEEE Trans. Semicond. Manuf* 9 (1996) 303.
- Chen W. C., Hsu, S. W. (2007). A neural-network approach for an automatic LED inspection system. *Expert Systems with Applications*, 33(3), 531-537

Using the hybrid Taguchi experimental design method – TOPSIS to identify the most suitable artificial neural networks used in energy forecasting

Ali Morovati Sharif Abadi

Alimorovati_ut@yahoo.com

Rasool Khancheh Mehr

Rs_Khanchehmehr@yahoo.com

Abstract

The use of artificial neural networks (ANN) in forecasting has many applications. Appropriate design of ANN parameters enhances the performance and accuracy of neural network models. Most studies use a trial and error approach in setting the value of ANN parameters. Other methods used to determine the best structure of a neural network only use a single evaluation criterion to determine the appropriate structure. In this study, the authors provide a new method to design the network structure. In this method, we use a combination of Taguchi experimental design and TOPSIS methods, to determine the optimal ANN structure, taking into account three evaluation criteria simultaneously. The estimated demand for gasoline in the Hormozgan province produced using this method, confirms its efficiency and effectiveness. Analysis of variance (ANOVA) of the ANN variables indicates that contribution of the number of neurons in the first hidden layer to the changes in the network performance is about 54% while the contribution of the learning algorithm is about 27%.

JEL: Q30, C45, Q47, C60

Keywords: artificial neural networks; Taguchi experimental design method; TOPSIS; Delphi fuzzy; Entropy.