

یافتن مناسب‌ترین ساختار شبکه عصبی مصنوعی با استفاده از روش طراحی آزمایشات تاگوچی

علی مروتی شریف آبادی*، رسول خوانچه مهر**

چکیده

تأخیر در تأمین نفت‌گاز، پیامدهای سیاسی، اجتماعی و اقتصادی وسیعی را به دنبال دارد؛ بنابراین پیش‌بینی دقیق تقاضای نفت‌گاز بسیار مهم است. استفاده از شبکه‌های عصبی مصنوعی در پیش‌بینی کاربرد زیادی دارد. طراحی مناسب پارامترهای (ساختار) شبکه موجب می‌شود دقت و عملکرد شبکه‌های عصبی مصنوعی افزایش یابد. در بیشتر مطالعات از روش سعی و خطا برای تنظیم پارامترهای شبکه‌های عصبی مصنوعی استفاده می‌شود که برای رسیدن به مناسب‌ترین ساختار شبکه‌های عصبی مصنوعی راه‌حل مطمئنی نیست. در مطالعه حاضر، با استفاده از روش طراحی آزمایشات تاگوچی، مناسب‌ترین ساختار شبکه‌های عصبی مصنوعی به منظور پیش‌بینی تقاضای نفت‌گاز در استان هرمزگان مشخص می‌شود. تجزیه و تحلیل واریانس پارامترهای شبکه‌های عصبی مصنوعی نشان می‌دهد که سهم مشارکت تعداد نرون در لایه پنهان اول در تغییر میانگین مربع خطای شبکه حدود ۴۱٪ و سهم مشارکت الگوریتم یادگیری نیز حدود ۲۷٪ است. همچنین نتایج نشان می‌دهد که شبکه‌های عصبی مصنوعی که با استفاده از روش طراحی آزمایشات تاگوچی طراحی شده‌اند، نسبت به سایر شبکه‌ها عملکرد بهتری دارند.

کلیدواژه‌ها: پیش‌بینی، نفت‌گاز، شبکه‌های عصبی مصنوعی، روش طراحی آزمایشات تاگوچی.

تاریخ دریافت مقاله: ۹۲/۹/۲۶، تاریخ پذیرش مقاله: ۹۲/۱۲/۲۳

* استادیار، دانشگاه یزد.

** دانش آموخته کارشناسی ارشد، نویسنده مسئول.

E-mail: Rs_Khanchehmeh@yahoo.com

۱. مقدمه

طبق تعریف، پیش‌بینی یک یا تعدادی برآورد کمی درباره احتمال وقایع آینده است که براساس اطلاعات حال و گذشته انجام می‌شود [۶]. پیش‌بینی‌ها همواره به‌عنوان راهنمایی برای خطامشی‌های دولتی و خصوصی به‌کار می‌روند؛ زیرا برنامه‌ریزی بدون داشتن دانش پیش‌بینی امکان‌پذیر نیست و به عبارت دیگر، داشتن پیش‌بینی مناسب از آینده، کارایی برنامه‌ریزی را بسیار تحت تأثیر قرار می‌دهد [۵].

از گذشته و به‌خصوص در چند دهه اخیر، پیش‌بینی وقایع و درک آینده زمینه پژوهش‌های زیادی بوده است. برآمد این تلاش‌ها، روش‌های گوناگونی است که بیشتر بر پایه مدل‌های آماری و اقتصادسنجی بنا شده‌اند. اگرچه روش‌های آماری و اقتصادسنجی، در زمینه پیش‌بینی سری‌های زمانی عملکرد نسبتاً خوبی داشته‌اند، محدودیت‌هایی نیز دارند؛ محدودیت اول این است که ممکن است در این‌گونه روش‌ها فرم تابعی متغیرهای مستقل و وابسته در صورت عدم شناخت کافی به‌درستی تصریح نشود، دیگری این است که داده‌های پرت ممکن است به تخمین اریب پارامترهای مدل بینجامد و سومین محدودیت این است که بیشتر مدل‌های سری زمانی، خطی هستند و در نتیجه در توضیح رفتارهای غیرخطی ناتوانند [۱]. در تحقیقات اخیر، از شبکه‌های عصبی مصنوعی^۱ به‌طور متداول به‌عنوان ابزار تقریب غیرخطی استفاده شده است و می‌توان با استفاده از آن بر مشکلات فوق فائق آمد [۲۵].

طی دهه گذشته، شبکه‌های عصبی مصنوعی به‌عنوان 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 دارد و برای مجموعه‌ای بزرگ و متنوع از مسائل، مناسب است [۳۳]. شبکه‌های عصبی مصنوعی در پیش‌بینی مسائلی که ناشناخته هستند و فرمول‌های ریاضی و دانش قبلی در رابطه با ورودی‌ها و خروجی‌های آن‌ها وجود ندارد، بسیار سودمند هستند [۳۰]. در مطالعات بسیاری، از شبکه‌های عصبی مصنوعی برای پیش‌بینی تقاضای انرژی استفاده شده است.

مدل‌سازی و پیش‌بینی تقاضای انرژی برای سیاست‌گذاران و سازمان‌های مرتبط در کشورهای توسعه‌یافته و در حال توسعه، نقش بسیار مهمی دارد [۲۸]. مدیریت تقاضای انرژی در حال تبدیل شدن به یک مسئله مهم است؛ زیرا جهان آینده به تصمیمات امروز وابسته است. مدیریت منابع انرژی به‌طور مطلوب، در میان برنامه‌ریزان و سیاست‌گذاران انرژی، به یک امر ضروری تبدیل شده است [۳۵]. بی‌توجهی به مصرف، به قطع بالقوه انرژی منجر می‌شود که نابودی زندگی و اقتصاد را در پی دارد. تخمین اضافی انرژی ممکن است به ایجاد ظرفیت بیهوده

1. Artificial Neural Network (ANN)

و غیرضروری منجر شود که به معنای اتلاف منابع مالی است؛ بنابراین بهتر است به منظور اجتناب از اشتباهات هزینه‌بر، از مدل‌هایی استفاده شود که مصرف انرژی را با دقت بسیار بالایی تخمین بزنند. همچنین بهتر است مدل‌هایی به کار گرفته شوند که بتوانند از داده‌های مصرف انرژی که ماهیت غیرخطی دارند، در پیش‌بینی استفاده کنند [۲۸]. با توجه به مطالعات گذشته، از تحلیل رگرسیون به عنوان پرفرودارترین روش در پیش‌بینی مصرف انرژی استفاده شده است. روش شبکه‌های عصبی مصنوعی، برای کاربران بالقوه نظیر مهندسين انرژی جذاب‌تر و دارای اهمیت بیشتری است؛ زیرا این روش مزیت‌هایی مانند محاسبه سریع، هزینه پایین، قابلیت انجام و طراحی آسان توسط کاربرانی با تجربه فنی کم دارد. بنابراین استفاده از ANN به منظور مدل‌سازی و پیش‌بینی، به طور فزاینده‌ای در دهه اخیر مورد توجه قرار گرفته است [۳۰].

ساختار شبکه باید با توجه به مسئله موردنظر توسط کاربر ایجاد شود و ساختارهای مختلف شبکه عصبی، پاسخ‌های متفاوتی ارائه می‌کنند. طراحی مناسب ساختار شبکه یا بهینه‌سازی پارامترهای شبکه عصبی مصنوعی (تعداد لایه‌های مخفی، تعداد نرون در لایه پنهان، الگوریتم آموزش و نرخ یادگیری)، عملکرد و دقت مدل شبکه عصبی را افزایش می‌دهد [۱۴]. روش آزمون و خطا شایع‌ترین روش تعیین ساختار شبکه عصبی است [۳۲]. 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 و در نتیجه یافتن بهترین جواب با کمترین خطا، از روش طراحی آزمایشات تاگوچی استفاده می‌کنند؛ زیرا با استفاده از روش طراحی آزمایشات تاگوچی، پارامتر معنی‌داری برای هر عامل^۱ و درصد تأثیر عوامل در پاسخ ارائه می‌شود. طراحی آزمایشات تاگوچی، از جمله شیوه‌های آماری است که ضمن حفظ صحت و دقت قابل قبول در نتایج، قادر است به طور چشمگیری از تعداد آزمایشات بکاهد. همچنین این روش قادر است که حالت بهینه‌ای از فرآیند یا شرایط مورد نظر را با توجه به متغیرهای مورد بررسی، تعیین کند [۱۷].

از آنجا که تأمین و توزیع به موقع نفت‌گاز، اصلی‌ترین منبع تأمین‌کننده انرژی، در بخش‌های متنوع اقتصادی کشور از قبیل نیروگاه‌ها، حمل‌ونقل، صنایع، کشاورزی و کشتیرانی اهمیت ویژه‌ای دارد و بروز هرگونه نارسایی در تأمین به موقع آن تبعات اقتصادی، سیاسی و اجتماعی دارد و باید تقاضای آن به صورت دقیق و با روش مناسب پیش‌بینی شود، محققان در تحقیق حاضر با استفاده از روش طراحی آزمایشات تاگوچی، مناسب‌ترین ساختار شبکه عصبی را به منظور پیش‌بینی تقاضای نفت‌گاز استان هرمزگان طی سال‌های ۱۳۹۲-۱۳۹۶ تعیین می‌کنند؛ بنابراین هدف اصلی تحقیق حاضر، مدل‌سازی و پیش‌بینی تقاضای نفت‌گاز در استان هرمزگان و هدف

فرعی، تعیین مهم‌ترین عوامل اثرگذار بر عملکرد شبکه‌های عصبی مصنوعی و میزان تأثیر هریک از عوامل است.

مهم‌ترین جنبه نوآوری در این تحقیق، استفاده از روش طراحی آزمایشات تاگوچی است. همان‌طور که گفته شد، در بیشتر 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 مزیت استفاده از روش تاگوچی نسبت به استفاده از روش‌های پیچیده فراابتکاری، در استفاده از محاسبات کمتر، ساده‌تر و سریع‌تر است.

در بخش دوم این پژوهش پیشینه پژوهش ارائه می‌شود، بخش سوم به معرفی شبکه‌های عصبی مصنوعی و روش طراحی آزمایشات تاگوچی و مراحل انجام تحقیق پرداخته می‌شود، یافته‌ها و تجزیه و تحلیل نتایج پژوهش در بخش چهارم ارائه می‌شوند و بحث و نتیجه‌گیری در بخش پنجم آمده است.

۲. مبانی نظری و پیشینه پژوهش

پیشینه پژوهش. همان‌طور که در بخش قبل گفته شد، در بیشتر 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 نفت‌گاز به‌عنوان 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. 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 این بخش برخی از مطالعات انجام‌شده در زمینه پیش‌بینی تقاضای نفت‌گاز و انرژی در دو قسمت مطالعات داخلی و مطالعات خارجی، ارائه می‌شود.

مطالعات داخلی. منه‌اج و همکاران با استفاده از شبکه‌های عصبی مصنوعی و با در نظر گرفتن شاخص‌های اقتصادی و اجتماعی، تقاضای انرژی بخش حمل‌ونقل کشور در سال‌های ۱۳۸۶ تا ۱۴۰۰ را پیش‌بینی کردند. آن‌ها از شبکه‌های عصبی روبه‌جلو با ناظر برای پیش‌بینی و از الگوریتم پس‌انتشار برای آموزش شبکه‌ها استفاده کردند. نتایج پیش‌بینی با این روش در مقایسه با روش رگرسیون چندمتغیره، دارای خطای به‌مراتب کمتری است؛ به طوری که درصد میانگین قدرمطلق خطا از ۱۵ به ۶ کاهش یافت. منه‌اج و همکاران در مطالعه مذکور، از روش سعی و خطا برای دستیابی به بهترین ساختار شبکه عصبی استفاده کرده‌اند [۱۱]. ابریشمی و همکاران از

شبکه عصبی^۱ GMDH، برای پیش‌بینی قیمت نفت‌گاز مبتنی بر قواعد تحلیل تکنیکی، شامل میانگین‌های متحرک کوتاه‌مدت و بلندمدت، به‌عنوان 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 [۱]. هم‌چنین، صادقی و همکاران با استفاده از شبکه عصبی مصنوعی مبتنی بر انتظارات قیمتی آن‌ها برای داده‌های روزانه، به مدل‌سازی و پیش‌بینی روزانه قیمت سبد نفت خام اوپک پرداختند و نتایج آن با مقادیر پیش‌بینی‌شده توسط مدل ARIMA براساس 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 [۹]. آخانی، به برآورد تابع تقاضای سوخت در بخش حمل‌ونقل با استفاده از مدل ۱۵ (به تفکیک هر زیربخش) پرداخت. در این تحقیق، با توجه به اهمیت حمل‌ونقل جاده‌ای کشور، بیشتر واحدهای انتخابی مربوط به تقاضای بنزین و نفت‌گاز در بخش جاده‌ای است. متغیرهای مهم برای برآورد تقاضای سوخت در زیربخش حمل‌ونقل، شامل قیمت سوخت، درآمد قابل تصرف، تعداد وسایل نقلیه موجود، عمر وسایل نقلیه، نرخ استفاده و کارایی آن‌ها، تعداد مسافر و میزان بار (تن) حمل شده برحسب کیلومتر، قیمت خدمات حمل‌ونقل و وضعیت خاص هر کشور (سیاست‌های دولت، وضعیت جنگی، آب و هوا و ...) است که با در نظر گرفتن وضعیت خاص هر کشور، می‌توان یکی از مدل‌های معرفی‌شده را انتخاب و برآورد کرد [۳].

اسماعیل‌نیا در پژوهشی، تابع تقاضای بنزین و نفت‌گاز را طی سال‌های ۱۳۴۶-۱۳۷۷ برآورد کرد. در این پژوهش، مصرف بنزین تابعی از تولید ناخالص داخلی بدون نفت به قیمت ثابت، قیمت حقیقی بنزین و موجودی وسایل نقلیه در نظر گرفته شد. نتایج این تحقیق نشان داد که بنزین کالایی کم‌کشش و ضروری است و به‌دلیل پایین بودن کشش آن عمدتاً تثبیت قیمت بنزین و نبود جایگزین مناسب برای آن است [۲].

میرفخرالدینی و همکاران 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 به‌عنوان 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 چندمتغیره، بالاترین دقت در پیش‌بینی مصرف انرژی کشور را دارد [۱۲].

مطالعات خارجی. از مطالعات خارجی انجام‌گرفته در زمینه تخمین تابع تقاضای حامل‌های انرژی، می‌توان به مطالعه پاگولاتوس^۱ [۳۱] اشاره کرد که تقاضا برای فرآورده‌های نفتی آمریکا، از جمله بنزین را با استفاده از روش حداقل مربعات معمولی برای دوره ۱۹۵۹-۱۳۷۲ تخمین زد. در این مقاله تقاضای سرانه بنزین تابعی از درآمد سرانه، قیمت بنزین و تقاضای سرانه بنزین در دوره قبل بود.

سیستم‌های هوشمند، به‌ویژه شبکه‌های عصبی، به‌دلیل عملکرد موفق در زمینه تشخیص و شناسایی مدل، در بسیاری از مسائل پیش‌بینی، مورد استفاده قرار گرفته‌اند که به‌طور نمونه می‌توان به موارد زیر اشاره کرد.

جیم و رُپر^۲ با استفاده از شبکه‌های عصبی مصنوعی، تقاضای انرژی در کشور کره جنوبی را برای سال‌های ۲۰۱۸ تا ۲۰۲۳ پیش‌بینی کردند. آن‌ها چهار عامل تولید ناخالص ملی، جمعیت، واردات و صادرات را به‌عنوان عوامل تأثیرگذار بر تقاضای انرژی در نظر گرفتند [۲۲]. ال سبا و ال امین^۳ با استفاده از یک شبکه پرسپترون چندلایه و الگوریتم پس‌انتشار، به پیش‌بینی انرژی الکتریکی پرداختند و نتیجه را با مدل‌های سری‌های زمانی مقایسه کردند. نتایج حاصل از پیش‌بینی با شبکه عصبی خطای کمتری را نسبت به مدل‌های سری‌های زمانی نشان داد و از دقت بالاتری برخوردار بود [۱۳]. کرمانشاهی و ایوامیا^۴ با استفاده از شبکه‌های عصبی، مصرف برق در ژاپن تا سال ۲۰۲۰ را پیش‌بینی کردند. آن‌ها از یک شبکه سه لایه و الگوریتم پس‌انتشار استفاده کردند و ورودی‌های شبکه را تولید ناخالص داخلی، جمعیت، تعداد خانوار، تعداد دستگاه تهویه هوا، میزان آلاینده دی‌اکسید کربن، شاخص تولید صنعتی، قیمت نفت، مصرف انرژی و قیمت برق در نظر گرفتند [۲۷].

جیم^۵ برای پیش‌بینی تقاضای انرژی بخش حمل‌ونقل انرژی 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 جابه‌جاشده را به‌عنوان ورودی شبکه‌های عصبی مصنوعی به‌کار برد. همچنین وی نشان داد که نتایج پیش‌بینی با استفاده از شبکه‌های عصبی مصنوعی از رگرسیون خطی چندگانه دقیق‌تر است [۲۱].

آزاده^۶ و همکاران با استفاده از شبکه‌های عصبی مصنوعی و به‌کار بردن متغیرهای محیطی و اقتصادی، مصرف انرژی تجدیدپذیر در ایران را پیش‌بینی کردند. متغیرهای ورودی در مدل آن‌ها

1. Pagolatus
2. Geem and Roper
3. Al-Saba and El-Amin
4. Kermanshahi and Iwamiya
5. Geem
6. Azadeh

عبارت‌اند از: انتشار دی‌اکسید کربن، انتشار نیتروژن اکسید، انتشار مونواکسید کربن، قیمت گاز، قیمت نفت و تولید ناخالص داخلی. آن‌ها چندین شبکه پرسپترون چندلایه 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 تجدیدپذیر را تعیین نمودند [۱۵]. رومبایان^۱ و همکاران برای پیش‌بینی پتانسیل انرژی خورشیدی در اندونزی، از شبکه‌های عصبی مصنوعی از نوع پرسپترون چندلایه و الگوریتم آموزش پس‌انتشار خطا استفاده کردند. آن‌ها داده‌های جغرافیایی و هواسنجی ۲۵ منطقه را برای آموزش و داده‌های ۵ منطقه را برای تست به‌کار بردند و با استفاده از روش سعی و خطا ساختار مناسب شبکه عصبی به‌منظور پیش‌بینی پتانسیل انرژی خورشیدی را مشخص کردند [۳۴].

اکونومو^۲ برای پیش‌بینی بلندمدت تقاضای انرژی کشور یونان از روش شبکه‌های عصبی مصنوعی از نوع پرسپترون چندلایه استفاده کرده و با استفاده از روش سعی و خطا، صدها ساختار را ایجاد و بهترین ساختار را انتخاب نموده است [۲۰]. آزاده و همکاران برای پیش‌بینی تقاضای ماهانه انرژی برق در ایران، روش شبکه‌های عصبی مصنوعی از نوع پرسپترون چندلایه را به‌کار بردند و برای تعیین تعداد نرون‌ها در لایه پنهان اول و دوم و دستیابی به بهترین ساختار شبکه، از روش سعی و خطا استفاده کردند [۱۶].

مبانی نظری. در این بخش، مطالب مختصری درمورد شبکه‌های عصبی مصنوعی، روش طراحی آزمایشات تاگوچی، روش تحقیق و مراحل انجام پژوهش برای یافتن بهترین ساختار شبکه عصبی مصنوعی را بیان می‌کنیم.

شبکه‌های عصبی مصنوعی. مطالعه درمورد شبکه‌های عصبی مصنوعی، به‌طور مشخص از سال ۱۹۴۳ توسط مک‌کلو و پیترز آغاز شد. از آنجا که هدف هوش مصنوعی توسعه پارادایم‌ها یا الگوریتم‌های مورد استفاده انسان به‌منظور کاربرد در ماشین است، شبکه‌های عصبی مصنوعی نیز به‌عنوان یکی از روش‌های هوش مصنوعی به‌دنبال تقلید از عملکرد مغز انسان است. شبکه‌های عصبی مصنوعی در دسته‌ای از سیستم‌های پویا قرار دارند که با پردازش داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. به این سیستم‌ها، هوشمند می‌گویند؛ زیرا براساس محاسبات روی داده‌های عددی یا مثال‌ها، قوانین کلی را فرامی‌گیرند [۲۲] به‌منظور موفقیت در انطباق با مسائل دنیای واقعی، باید ابعاد زیادی،

1. Rumbayan
2. Ekonomou

از جمله مدل شبکه، اندازه شبکه، تابع فعالیت، پارامترهای یادگیری و تعداد نمونه‌های آموزشی را مورد توجه قرار داد [۴]. 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 برخلاف روش‌های سنتی آماری هیچ پیش‌فرضی در مورد توزیع و یا خواص آماری داده‌ها به‌عمل نمی‌آورند و از این نظر می‌توانند کارایی زیادی داشته باشند. همچنین این شبکه‌ها، در زمره 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 [۱۰]. شبکه‌های عصبی مصنوعی، انواع مختلفی دارند. با توجه به اینکه در پژوهش‌های بسیاری، از شبکه پرسپترون^۱ چندلایه به‌همراه الگوریتم پس‌انتشار خطا^۲ استفاده شده است، در تحقیق حاضر نیز از این نوع شبکه استفاده شده است.

طراحی آزمایشات تاگوچی. به‌واسطه‌ی دانش طراحی آزمایشات، میزان تأثیرگذاری هر یک از عوامل مؤثر بر فرآیند تبدیل ورودی به خروجی مشخص می‌شود. طراحی آزمایشات روش‌های گوناگونی دارد که به‌کار بردن هر یک از آن‌ها با مجموعه‌ای از مزایا و معایب همراه است و محدودیت‌هایی را به‌دنبال دارد. یکی از بهترین روش‌های طراحی آزمایش، روش تاگوچی است؛ زیرا تاگوچی رویکردی را برای رسیدن به استواری ارائه می‌دهد و برای تحقق این هدف، از ابزارهایی نظیر آرایه‌های متعامد^۳ که تعداد آزمایشات را کاهش می‌دهد و نسبت سیگنال به نویز یا مطلوبیت به بدی کارکرد^۴ (S/N) که هم‌زمان مناسب‌ترین ترکیب و مؤثرترین معیار را مشخص می‌سازد، استفاده می‌کند. طراحی استوار یک روش مهندسی بهبود کیفیت است که بهترین فرآیند را برای توسعه محصول، با توجه به نیازمندی‌های مشتری طراحی می‌کند [۱۸].

۳. روش‌شناسی پژوهش

همه تحقیقات با توجه به سه بعد هدف، میزان کنترل متغیرها و روش گردآوری داده‌ها مورد بررسی قرار می‌گیرند. تحقیق حاضر از نظر نوع هدف کاربردی، از نظر میزان کنترل متغیرها توصیفی و از نظر روش گردآوری داده‌ها کتابخانه‌ای به‌شمار می‌رود. برای پوشش مباحث تئوریک تحقیق، از کتب عمومی و تخصصی، مقالات و نشریات تخصصی استفاده شده است. در این

-
1. Multi-Layer Perceptron
 2. Error Back Propagation
 3. Orthogonal Arrays (OA)
 4. Signal / Noise

تحقیق جامعه آماری دربرگیرنده تمامی مصرف‌کنندگان نفت‌گاز در استان هرمزگان در بخش‌های مختلف کشاورزی، تولیدی و ... است. با توجه به ماهیت تحقیق، نمونه‌گیری از جامعه صورت نگرفته و تمام جامعه مورد بررسی قرار گرفته است.

مراحل انجام پژوهش. مراحل انجام این تحقیق به شرح زیر است:

گام ۱: در این مرحله از تحقیق، ادبیات موضوعی در زمینه پیش‌بینی تقاضای حامل‌های انرژی به‌خصوص نفت‌گاز، شبکه‌های عصبی مصنوعی، روش طراحی آزمایشات تاگوچی مطالعه شد. مرور ادبیات با هدف شناخت بیشتر و بهتر روش‌ها، عوامل مؤثر بر تقاضای نفت‌گاز و مطالعات گذشته در مورد پیش‌بینی تقاضای نفت‌گاز صورت گرفت.

گام ۲: با توجه به پیشینه تحقیق، مهم‌ترین عوامل مؤثر بر تقاضای نفت‌گاز عبارت‌اند از: جمعیت، تولید ناخالص داخلی و صادرات و واردات.

گام ۳: پس از تعیین مهم‌ترین عوامل مؤثر بر تقاضای نفت‌گاز، داده‌های مورد نیاز مربوط به سال‌های ۱۳۵۱-۱۳۹۰، با استفاده از مستندات شرکت ملی پخش فرآورده‌های نفتی، وزارت نیرو و بانک مرکزی جمع‌آوری شد.

استفاده از داده‌ها به‌صورت خام، باعث کاهش سرعت و دقت شبکه می‌شود. برای جلوگیری از چنین حالتی و یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال‌سازی داده‌ها صورت می‌گیرد. عمل نرمال‌سازی مانع از کوچک شدن بیش از حد وزن‌ها و اشباع زود هنگام نرون‌ها می‌شود [۸]. با استفاده از رابطه زیر، داده‌ها نرمال‌ایز شدند.

$$y = 0.8 \times \frac{X_i - X_{min}}{X_{max} - X_{min}} + 0.1 \quad \text{رابطه ۱}$$

در رابطه بالا، y مقدار نرمال‌شده پارامتر، X_i مقدار واقعی هر پارامتر، X_{max} بیشترین مقدار پارامتر مورد نظر و X_{min} کمترین مقدار پارامتر است.

گام ۴: با مطالعه ادبیات مربوط به شبکه‌های عصبی مصنوعی، مشخص می‌شود که چندین عامل در طراحی ساختار مناسب شبکه عصبی مؤثرند.

ایجاد یک ساختار مناسب شبکه عصبی برای یک کاربرد خاص، بسیار مهم است. چهار پارامتر شبکه‌های عصبی مصنوعی، به‌عنوان مهم‌ترین متغیرهای بهینه‌سازی عملکرد شبکه شناسایی شده‌اند. این چهار پارامتر عبارت‌اند از: تعداد نرون‌ها در لایه مخفی اول، تعداد نرون‌ها در لایه مخفی دوم [۱۹]، نوع الگوریتم آموزش و نرخ یادگیری. در پژوهش حاضر، با استفاده از روش طراحی آزمایشات تاگوچی، سطح مناسب چهار پارامتر اصلی شبکه عصبی و در نتیجه ساختار مناسب شبکه برای پیش‌بینی مصرف فرآورده‌های نفتی، تعیین می‌شود.

گام ۵: سطح عامل، مقادیر یا حالاتی است که برای عامل در نظر گرفته می‌شود. سطوح مربوط به تعداد نرون‌ها در لایه‌های پنهان اول و دوم [۱۹] در جدول ۱ و سطوح مربوط به نرخ یادگیری [۲۶] و الگوریتم آموزش [۱۴] در جدول ۲ آمده است.

جدول ۱. تعداد نرون‌ها در لایه‌های پنهان (تعداد ورودی‌ها= N ، تعداد خروجی‌ها= P)

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

جدول ۲. سطوح مربوط به عوامل نرخ یادگیری و الگوریتم آموزش

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

با توجه به جدول ۱ و اینکه در تحقیق حاضر، ورودی‌های شبکه عصبی برای پیش‌بینی تقاضای نفت‌گاز، چهار عامل جمعیت، تولید ناخالص داخلی، صادرات و واردات ($N=4$) و خروجی شبکه میزان تقاضای نفت‌گاز ($OP=1$) است، سطوح مربوط به دو عامل تعداد نرون‌ها در لایه پنهان اول و دوم شبکه عصبی برای پیش‌بینی تقاضای نفت‌گاز، مطابق جدول ۳ است.

جدول ۳. سطوح مربوط به تعداد نرون‌ها در لایه پنهان اول و دوم شبکه عصبی برای پیش‌بینی نفت‌گاز

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

سطوح مربوط به عامل‌های نرخ یادگیری (C) و الگوریتم آموزش (D) برای شبکه‌های عصبی به‌منظور پیش‌بینی تقاضای نفت‌گاز، در جدول ۲ آمده است.

گام ۶: در این مرحله، باید آرایه متعامد مناسب با توجه به درجه آزادی کل آزمایش تعیین شود. از آنجا که در این پژوهش، چهار عامل چهارسطحی وجود دارد، درجه آزادی کل آزمایش برابر است با ۸ ($4 \times (3-1) = 8$)؛ بنابراین آرایه متعامد $L_9(3^4)$ انتخاب می‌شود [۲۹]. آرایه متعامد $L_9(3^4)$ در جدول ۴ آمده است.

جدول ۴. 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

سپس، باید ساختارهای مختلف شبکه عصبی مصنوعی، مطابق آرایه متعامد که در جدول ۴ آمده است، طراحی و اجرا شوند.

گام ۷: ساختار شبکه‌های عصبی برای پیش‌بینی تقاضای نفت‌گاز، مطابق آزمایش‌های آورده‌شده در آرایه متعامد موجود در جدول ۴، طراحی و اجرا شده‌اند؛ به عنوان مثال، برای انجام آزمایش ششم، آرایه متعامد آورده شده در جدول ۴، شبکه عصبی با ۹ نرون در لایه پنهان اول، ۷ نرون در لایه پنهان دوم، الگوریتم آموزش Scaled Conjugate Gradient و نرخ یادگیری $0/3$ طراحی و اجرا می‌شود.

گفتنی است که داده‌های سال‌های ۱۳۵۰-۱۳۸۵ به‌عنوان داده‌های آموزش و داده‌های ۱۳۸۶-۱۳۹۰ به‌عنوان داده‌های تست به‌کار رفته‌اند.

در این مرحله، باید معیار انتخاب بهترین شبکه مشخص شود. شاخص‌های کمی بسیاری به‌منظور ارزیابی عملکرد شبکه عصبی مصنوعی وجود دارند که میانگین مربعات خطا یکی از آن‌ها است. میانگین مربعات خطا از رابطه زیر محاسبه می‌شود و در آن بیانگر تعداد عناصر پردازنده خروجی است. N تعداد نمونه‌های شبکه‌های داده‌ها را نشان می‌دهد. Y_{ij} خروجی شبکه

برای نمونه i در عنصر پردازنده j است. d_{ij} خروجی مطلوب برای نمونه i در عنصر پردازنده j است [۸].

$$MSE = \frac{\sum_{j=0}^P \sum_{i=0}^N (d_{ij} - y_{ij})^2}{NP} \quad \text{رابطه ۲}$$

از آنجا که در تحقیق حاضر، برای سنجش عملکرد شبکه‌های عصبی مصنوعی از معیار MSE استفاده می‌شود، خروجی یا نتیجه اجرای هریک از آزمایش‌ها برابر MSE حاصل از اجرای شبکه عصبی مطابق با آزمایش مربوطه است.

برای ارزیابی دقیق‌تر و مناسب‌تر هریک از ساختارهای شبکه‌های عصبی و حصول اطمینان از نتایج به‌دست آمده، هر ساختار طراحی‌شده (آزمایش) ۵ بار اجرا می‌شود. روش تاگوشی برای بررسی پراکندگی پاسخ‌ها از تابع مربع انحراف استاندارد (MSD) استفاده می‌کند. پس از محاسبه S/N، این نسبت به‌عنوان پاسخ آزمایش موردنظر در نظر گرفته می‌شود و تجزیه و تحلیل‌ها براساس آن صورت می‌گیرد.

برای تبدیل پاسخ‌ها (۵ پاسخ) به یک پاسخ واحد، از آنجا که هرچه مقدار MSE کوچک‌تر باشد، عملکرد شبکه بهتر است و مقدار کوچک‌تر MSE مطلوب‌تر است، از رابطه زیر استفاده شده است.

$$MSD = \frac{(y_1^2 + y_2^2 + \dots + y_r^2)}{r} \Rightarrow \frac{S}{N} = -10 \log \left(\frac{1}{r} \sum_{i=1}^n y_i^2 \right) \quad \text{رابطه ۳}$$

در رابطه بالا، r تعداد تکرار است.

نتایج حاصل از اجرای ساختارهای شبکه عصبی برای پیش‌بینی تقاضای نفت‌گاز که مطابق جدول ۴ طراحی شده‌اند و نتایج حاصل از تبدیل مقادیر MSE به یک پاسخ و براساس رابطه ۳، در جدول ۵ آمده است.

جدول ۵. نتایج حاصل از اجرای ساختارهای شبکه عصبی برای پیش‌بینی تقاضای نفت‌گاز

S/N	Y	Y5	Y4	Y3	Y2	Y1	شماره آزمایش
۴۱/۴۶۰	۰/۰۰۸۴۲	۰/۰۰۷۷	۰/۰۰۷۸	۰/۰۰۹۷	۰/۰۰۸۱	۰/۰۰۸۸	۱
۴۱/۵۳۹	۰/۰۰۸۳۴	۰/۰۰۷۲	۰/۰۰۸۹	۰/۰۰۸۶	۰/۰۰۷۷	۰/۰۰۹۳	۲
۳۸/۴۸۶	۰/۰۱۱۸۶	۰/۰۱۰۴	۰/۰۱۱۷	۰/۰۱۲۹	۰/۰۱۱۲	۰/۰۱۳۱	۳
۴۵/۲۲۵	۰/۰۰۵۴۴	۰/۰۰۵۶	۰/۰۰۶۳	۰/۰۰۵۷	۰/۰۰۴۳	۰/۰۰۵۳	۴
۴۱/۵۶۷	۰/۰۰۸۲۸	۰/۰۰۶۲	۰/۰۰۸۴	۰/۰۰۹۲	۰/۰۰۸۷	۰/۰۰۸۹	۵
۴۴/۱۴۰	۰/۰۰۶۱۲	۰/۰۰۷۶	۰/۰۰۶۸	۰/۰۰۵۱	۰/۰۰۴۸	۰/۰۰۶۳	۶
۴۲/۲۷۴	۰/۰۰۷۴۶	۰/۰۰۹۱	۰/۰۰۷۲	۰/۰۰۷۵	۰/۰۰۸۱	۰/۰۰۶۳	۷
۳۹/۱۴۲	۰/۰۱۱۰۲	۰/۰۱۱۵	۰/۰۱۰۹	۰/۰۰۹۹	۰/۰۱۱۷	۰/۰۱۱۱	۸
۴۳/۲۰۰	۰/۰۰۶۸۶	۰/۰۰۸۲	۰/۰۰۷۴	۰/۰۰۶۱	۰/۰۰۶۹	۰/۰۰۵۷	۹

گام ۱: برای تعیین بهترین ساختار شبکه عصبی، پس از انجام آزمایشات (اجرای شبکه‌های عصبی) و محاسبه نتیجه آزمایشات (مقدار MSE)، باید سطح بهینه هریک از عامل‌ها مشخص شود. به منظور تعیین سطح بهینه هریک از عامل‌ها، باید اثر اصلی عامل‌ها در هریک از سطوح محاسبه شود. اثر اصلی هریک 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).

$$\bar{A}_L = \frac{\sum Y_i}{N} \quad i @ L=1 \text{ or } L=2 \text{ or } \dots \quad \text{رابطه ۴}$$

با استفاده از تجزیه و تحلیل‌های مربوط به روش طراحی آزمایشات تاگوچی، مناسب‌ترین سطح مربوط به هریک از عوامل و در نتیجه، ساختاری که کمترین میانگین مربعات خطا را داشته باشد، تعیین و مشخص می‌شود.

گام ۹: بعد از تعیین شرایط بهینه، باید پاسخ در این شرایط^۱ (Y_{exp.}) محاسبه شود. اگر شرایط بهینه به دست آمده جزو آزمایش‌ها نباشد، باید آزمایشی در شرایط بهینه پیش‌بینی شده انجام شود و نتایج آن با Y_{exp.} مقایسه شود. Y_{exp.} از رابطه زیر محاسبه می‌شود.

$$Y_{exp.} = Y_{ave} + (\bar{A}_0 - Y_{ave}) + (\bar{G}_0 - Y_{ave}) + \dots \quad \text{رابطه ۵}$$

\bar{A}_0 اثر اصلی عامل A در سطح بهینه است و Y_{ave} میانگین پاسخ تمامی آزمایش‌ها که از رابطه زیر حاصل می‌شود [۷].

$$Y_{ave} = \frac{\sum Y_i}{n} \quad \text{رابطه ۶}$$

در این مرحله، باید ساختار مناسب تعیین شده از طریق تجزیه و تحلیل‌های مربوط به روش طراحی آزمایشات تاگوچی، اجرا شود و نتایج با مقادیر پیش‌بینی شده مقایسه شود. همچنین باید ساختار بهینه تعیین شده با استفاده از روش تاگوچی، با سایر ساختارها مقایسه شود تا بهتر و مناسب‌تر بودن ساختار تعیین شده، مشخص و تأیید گردد. نتایج حاصل از گام‌های ۸ و ۹، در بخش بعدی ارائه شده است.

۴. تحلیل داده‌ها و یافته‌های پژوهش

تعیین بهترین ساختار شبکه عصبی مصنوعی. 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 نفت‌گاز، در جدول ۶ آمده است.

جدول ۶. اثرات اصلی عوامل بر عملکرد شبکه‌های عصبی در پیش‌بینی تقاضای نفت‌گاز

عوامل	اثرات اصلی		
	سطح سه	سطح دو	سطح یک
تعداد نرون‌ها در لایه پنهان اول (A)	۴۱/۵۴	۴۳/۶۴	۴۰/۵۰
تعداد نرون‌ها در لایه پنهان دوم (B)	۴۱/۹۴	۴۰/۷۵	۴۲/۹۹
نوع الگوریتم آموزش (C)	۴۰/۷۸	۴۳/۳۲	۴۱/۵۸
نرخ یادگیری (D)	۴۲/۶۵	۴۰/۹۵	۴۲/۰۸

گفتنی است که همواره برای شرایط بهینه، مقدار ماکسیمم S/N مورد نظر است و از آنجا که نتایج اعلام‌شده در جدول‌های بالا، برحسب S/N است، بهترین سطح هریک از عوامل با توجه به محاسبات ارائه‌شده در جدول ۶ به شرح جدول ۷ است.

جدول ۷. سطح بهینه عوامل در ساختار شبکه عصبی برای پیش‌بینی تقاضای نفت‌گاز

عوامل	سطح بهینه
تعداد نرون‌ها در لایه پنهان اول (A)	سطح دو (۹ نرون)
تعداد نرون‌ها در لایه پنهان دوم (B)	سطح یک (۳ نرون)
نوع الگوریتم آموزش (C)	سطح دو (Levenberg-Marquardt)
نرخ یادگیری (D)	سطح سه (۰/۳)

با توجه به جدول ۷، بهترین ساختار شبکه عصبی برای پیش‌بینی تقاضای نفت‌گاز، ساختاری با ۹ نرون در لایه پنهان اول، ۳ نرون در لایه پنهان دوم، الگوریتم آموزش Levenberg-Marquardt و نرخ یادگیری یک‌دهم (۰/۳) است.

تعیین میزان تأثیر هریک از عوامل بر عملکرد شبکه عصبی مصنوعی. همان‌طور که بیان شد، چهار پارامتر شبکه‌های عصبی مصنوعی به‌عنوان مهم‌ترین متغیرهای بهینه‌سازی عملکرد شبکه، شناسایی شده‌اند. این چهار پارامتر عبارت‌اند از: تعداد نرون‌ها در لایه پنهان اول، تعداد نرون‌ها در لایه پنهان دوم، نوع الگوریتم آموزش و نرخ یادگیری. در این بخش، میزان تأثیر هریک از عوامل بر عملکرد شبکه عصبی محاسبه و بیان می‌شود.

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 هریک از عوامل در عملکرد شبکه عصبی که برای پیش‌بینی تقاضای نفت‌گاز استفاده می‌شود، در جدول ۸ ارائه شده است.

جدول ۸. سهم مشارکت عوامل در عملکرد شبکه عصبی برای پیش‌بینی تقاضای نفت‌گاز

Percent P (%)	Pur Sum (S')	Variance (V)	Sum of Sqrs (S)	DOF	Factors
۴۱/۰۶۳	۱۵/۴۳۹	۷/۷۱۹	۱۵/۴۳۹	۲	تعداد نرون‌ها در لایه پنهان اول
۱۹/۹۸۹	۷/۵۱۵	۳/۷۵۸	۷/۵۱۵	۲	تعداد نرون‌ها در لایه پنهان دوم
۲۷/۰۲۱	۱۰/۱۶۰	۵/۰۸۰	۱۰/۱۶۰	۲	نوع الگوریتم آموزش
۱۱/۹۲۷	۴/۴۸۴	۲/۲۴۲	۴/۴۸۴	۲	نرخ یادگیری
.	Error
۱۰۰			۳۷/۵۹۸	۸	Total

با توجه به نتایج ارائه‌شده در جدول ۸، عامل تعداد نرون‌ها در لایه پنهان اول بیش از سایر عوامل بر عملکرد شبکه عصبی تأثیرگذار است. درحالی که سهم مشارکت عامل تعداد نرون‌ها در لایه پنهان اول در تغییر میزان MSE (نشانه عملکرد شبکه است) شبکه عصبی حدود ۴۱ درصد است، سهم مشارکت عامل تعداد نرون‌ها در لایه پنهان دوم شبکه عصبی حدود ۲۰ درصد است. سهم مشارکت عامل نوع الگوریتم آموزش و نرخ یادگیری در تغییر میزان MSE شبکه عصبی، به ترتیب برابر ۲۷/۰۲۱ و ۱۱/۹۲۷ درصد است.

پیش‌بینی پاسخ در شرایط بهینه و انجام آزمایش تأییدی. بعد از اینکه ساختار بهینه شبکه عصبی مصنوعی برای پیش‌بینی تقاضای نفت‌گاز مشخص شده است و ساختار مورد نظر در بین آزمایش‌های انجام‌شده وجود ندارد، باید عملکرد این شبکه در حالت بهینه را پیش‌بینی و محاسبه کرد.

Y_{exp} مربوط به ساختار مناسب شبکه عصبی مصنوعی به‌منظور پیش‌بینی تقاضای نفت‌گاز براساس روابط ۵ و ۶ مطابق جدول ۹ است.

جدول ۹. Y_{exp} مربوط به ساختار مناسب شبکه عصبی به‌منظور پیش‌بینی تقاضای نفت‌گاز

Y_{exp}	سطح مناسب عامل D	سطح مناسب عامل C	سطح مناسب عامل B	سطح مناسب عامل A	Y_{ave}
۴۶/۹۳	۴۲/۶۵	۴۳/۳۲	۴۲/۹۹	۴۳/۶۴	۴۱/۸۹

باید توجه شود که Y_{exp} محاسبه شده در جدول ۹، برحسب S/N است و باید به پاسخ‌های اولیه (MSE) تبدیل شود. بر همین اساس، می‌توان نوشت:

$$MSD = 10^{-\left(\frac{S}{N}\right)/10} \quad \text{رابطه ۷}$$

از طرفی برای پاسخ‌های از نوع کمتر بهتر، معادله زیر حاکم است:

$$MSD = \frac{(y_1^2 + y_2^2 + \dots + y_r^2)}{r} \quad \text{رابطه ۸}$$

برای محاسبه تقریبی جواب در شرایط بهینه، فرض می‌شود همه پاسخ‌ها معادل پاسخ مورد انتظار است؛ در نتیجه معادله بالا به صورت زیر نشان داده می‌شود [۷]:

$$MSD = \frac{r (Y_{exp})^2}{r} \rightarrow Y_{exp} = (MSD)^{1/2} \quad \text{رابطه ۹}$$

Y_{exp} برحسب پاسخ‌های اولیه (MSE) مربوط به ساختار مناسب برای پیش‌بینی تقاضای نفت‌گاز مطابق رابطه‌های بالا محاسبه شده است و مطابق جدول ۱۰ است.

جدول ۱۰: Y_{exp} برحسب S/N پاسخ‌های اولیه (MSE)

برحسب S/N Y_{exp}	برحسب MSE Y_{exp}
۴۶/۹۳	۰/۰۰۴۵

نکته قابل ذکر در اینجا این است که بازه اطمینان برای Y_{exp} در سطح اعتماد ۹۰ درصد، از رابطه زیر محاسبه می‌شود [۲۴]:

$$CI = \sqrt{F_{0.1,1,df} \times v_e \times \left(\frac{1}{n_{eff}}\right)} \quad \text{رابطه ۱۰}$$

در رابطه بالا، df درجه آزادی خطا است. هم‌چنین، v_e نشان‌دهنده واریانس خطا است و n_{eff} برابر است با تقسیم تعداد کل آزمایشات بر درجه آزادی عامل‌هایی که در محاسبه Y_{exp} استفاده شده‌اند. از آنجا که در تحقیق حاضر، درجه آزادی خطا برابر صفر است، درجه آزادی و واریانس عاملی که کمترین سهم مشارکت را دارد، به‌عنوان درجه آزادی و واریانس خطا در نظر گرفته می‌شود. نتایج حاصل از محاسبه CI مربوط Y_{exp} برای پیش‌بینی تقاضای نفت‌گاز برحسب S/N و نیز برحسب MSE در جدول ۱۱ ارائه شده است.

جدول ۱۱. نتایج حاصل از محاسبه CI مربوط Y_{exp} برحسب S/N و نیز برحسب MSE

بازه قابل قبول پاسخ برحسب MSE	Y_{exp} برحسب MSE	بازه قابل قبول پاسخ برحسب S/N	CI	Y_{exp} برحسب S/N
۰/۰۰۳۰ - ۰/۰۰۶۸	۰/۰۰۴۵	۵۰/۵۰ - ۴۳/۳۶	۳/۵۷	۴۶/۹۳

با توجه به نتایج ارائه شده در جدول ۱۱، اگر ساختار مناسب شبکه عصبی برای پیش‌بینی تقاضای نفت‌گاز (۹ نرون در لایه پنهان اول، ۳ نرون در لایه پنهان دوم، الگوریتم آموزش Levenberg-Marquardt و نرخ یادگیری ۰/۳) طراحی و اجرا شود، باید مقدار MSE در بازه ۰/۰۰۳۰ تا ۰/۰۰۶۸ و مقدار S/N در محدوده ۴۳/۳۶ تا ۵۰/۵۰ قرار گیرد تا بهینه بودن ساختار طراحی شده تأیید شود. در این مرحله، با انجام آزمایش‌های تأییدی، مناسب بودن ساختار بهینه و جواب در شرایط بهینه، بررسی می‌شود؛ بنابراین برای حصول اطمینان از مناسب بودن ساختار ذکر شده، طبق یافته‌های تحقیق حاضر و با توجه به جدول ۷، بهترین ساختار شبکه عصبی برای پیش‌بینی تقاضای نفت‌گاز، ۵ بار طراحی و اجرا شده است. نتایج حاصل از اجرای شبکه عصبی با ساختار بهینه، برحسب MSE و S/N در جدول زیر آمده است.

جدول ۱۲. نتایج حاصل از اجرای شبکه عصبی با ساختار بهینه، برحسب MSE و S/N

S/N	\bar{Y}	Y5	Y4	Y3	Y2	Y1
۴۵/۴۲	۰/۰۰۵۲۲	۰/۰۰۶۲	۰/۰۰۴۴	۰/۰۰۵۸	۰/۰۰۴۹	۰/۰۰۵۳

با توجه به نتایج ارائه شده در جدول ۱۲، مقادیر MSE و S/N در آزمایش‌های تأییدی (اجرای ساختار بهینه شبکه‌های عصبی) انجام شده به منظور پیش‌بینی تقاضای نفت‌گاز، در محدوده مجاز MSE (۰/۰۰۳۰ - ۰/۰۰۶۸) و محدوده مجاز S/N (۴۳/۳۶ - ۵۰/۵۰) قرار دارد. به این ترتیب بهینه و مناسب‌تر بودن ساختار شبکه عصبی معرفی شده برای پیش‌بینی تقاضای نفت‌گاز (۹ نرون در لایه پنهان اول، ۳ نرون در لایه پنهان دوم، الگوریتم آموزش Levenberg-Marquardt و نرخ یادگیری ۰/۳)، نسبت به سایر ساختارهای شبکه عصبی، تأیید می‌شود. با توجه به مقادیر MSE و S/N ارائه شده در جدول ۱۲، مشخص می‌شود که مقادیر MSE مربوط به اجرای ساختار بهینه شبکه‌های عصبی به منظور پیش‌بینی نفت‌گاز، از مقادیر MSE مربوط به سایر ساختارهایی که در جدول ۵ آمده کمتر و از S/N بیشتر است. این موضوع نیز نشان‌دهنده کارایی بیشتر ساختار بهینه شبکه عصبی که با استفاده از طراحی آزمایشات تاگوچی ایجاد شده‌اند، از ساختارهای دیگر است.

۵. نتیجه‌گیری و پیشنهادها

با توجه به اهمیت پیش‌بینی تقاضای فرآورده‌های نفتی به‌عنوان یک موضوع مهم و تأثیرگذار که همواره مورد توجه دولت‌ها بوده است، تمرکز مطالعه حاضر بر یافتن بهترین ساختار شبکه عصبی مصنوعی با به‌کارگیری طراحی آزمایشات تاگوچی، به‌منظور پیش‌بینی تقاضای نفت‌گاز است. بدین منظور، ابتدا با بررسی مطالعات گذشته در حوزه پیش‌بینی انرژی، مهم‌ترین عوامل اثرگذار بر تقاضای نفت‌گاز و مصرف انرژی مشخص شدند و با مطالعه پژوهش‌های مرتبط با حوزه شبکه‌های عصبی مصنوعی، مهم‌ترین پارامترهای اثرگذار بر عملکرد شبکه‌های عصبی شناسایی گردیدند. سپس داده‌های مربوطه جمع‌آوری و به‌عنوان ورودی شبکه عصبی مصنوعی در نظر گرفته شدند. در مرحله بعد، با استفاده از روش طراحی آزمایشات تاگوچی، بهترین ساختار شبکه عصبی به‌منظور پیش‌بینی تقاضای نفت‌گاز طراحی شده است. یافته‌های پژوهش نشان می‌دهد که با استفاده از روش تاگوچی می‌توان بهترین ساختار شبکه عصبی مصنوعی را با توجه به هدف مورد نظر تعیین کرد. در بیشتر مطالعات، از روش سعی و خطا برای تنظیم پارامترهای شبکه‌های عصبی مصنوعی استفاده می‌شود که برای رسیدن به مناسب‌ترین ساختار شبکه‌های عصبی مصنوعی راه‌حل مطمئنی به‌شمار نمی‌رود. نتایج تحقیق حاضر نشان می‌دهد که استفاده از روش طراحی آزمایشات راهی مناسب برای تعیین بهترین ساختار و تنظیم پارامترهای شبکه‌های عصبی مصنوعی است و کارایی و دقت شبکه‌های طراحی‌شده با روش مذکور، بیشتر از شبکه‌های دیگر است. در ادامه، پیشنهاداتی را برای انجام تحقیقات آتی ارائه می‌دهیم:

۱. تقاضای فرآورده‌های نفتی، به تفکیک بخش‌های مختلف اقتصادی، پیش‌بینی و مقایسه شود تا بخش‌های پرمصرف شناسایی شوند؛

۲. ورودی‌هایی مثل قیمت فرآورده‌های نفتی و سیاست‌های آتی دولت در خصوص اصلاح مصرف فرآورده‌های نفتی در بخش‌های مختلف اقتصادی و شاخص‌های مرتبط دیگر مورد توجه قرار گیرند؛

۳. از آنجا که رویکرد شبکه‌های عصبی فازی روشی قدرتمند در پیش‌بینی موضوعات مختلف مدیریتی است، از روش ترکیبی شبکه عصبی مصنوعی و منطق فازی (ANFIS) استفاده شود؛

۴. سایر پارامترهای شبکه عصبی مصنوعی، نظیر تابع فعالیت، میزان داده‌های آموزش و ... در نظر گرفته شوند؛

۵. از روش ترکیبی شبکه‌های عصبی مصنوعی و طراحی آزمایشات تاگوچی برای پیش‌بینی موضوعاتی همچون پیش‌بینی رشد اقتصادی، میزان مصرف برق، میزان بارندگی و ... استفاده شود.

منابع

۱. ابریشمی؛ حمید، غنیمی فرد؛ حجت اله، مهدی و منیژه رضایی (۱۳۸۹). پیش‌بینی قیمت نفت‌گاز خلیج فارس، مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی. *فصلنامه مطالعات اقتصاد انرژی*. سال هفتم، شماره ۲۴، صص ۱۹۲-۱۷۱.
۲. اسماعیل‌نیا، علی اصغر (۱۳۷۸). بررسی افزایش قیمت بنزین روی مصرف آن. *مجله‌ی برنامه و بودجه*. شماره ۵۳، صص ۶۱-۳۳.
۳. آخانی، زهرا (۱۳۷۸). برآورد تابع تقاضای سوخت در بخش حمل و نقل در ایران برای سال‌های ۷۴-۱۳۵۶. *مجله‌ی برنامه و بودجه*. شماره ۳۸ و ۳۹، صص ۱۲۸-۱۰۱.
۴. 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.
۵. 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 ۴۶-۲۵.
۶. چتفیلد، سی (۱۳۸۹). مقدمه‌ای بر تحلیل سری‌های زمانی. ترجمه نیرومند؛ حسینعلی، بزرگ نیا؛ ابوالقاسم. انتشارات دانشگاه فردوسی، مشهد، چاپ سوم.
۷. زینالی؛ الهام (۱۳۸۷). طراحی آزمایش به روش تاگوچی با استفاده از نرم افزار Qualitek. نشر شرکت پژوهش و فناوری پتروشیمی.
۸. 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.
۹. 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 ۴۷-۲۵.
۱۰. 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.
۱۱. منهای؛ محمد باقر، کاظمی؛ عالی، 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.
۱۲. میرفخرالدینی؛ سید حیدر، بابایی میبدی؛ 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 ۲۲۲-۱۹۷.

13. Al-Saba, T. & El-Amin, I. (1999). Artificial neural networks as applied to long-term demand forecasting. *Artificial Intelligence in Engineering*, 13.
14. 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.
15. 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, 605 - 612.
16. Azadeh, A., Ghaderi, S.F. & Sohrabkhani, S. (2008). A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran. *Energy Policy*, 36, 2637- 2644.
17. 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.
18. 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, 667-681.
19. 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.
20. Ekonomou, L. (2010). Greek long-term energy consumption prediction using artificial neural networks. *Energy*, 35, 512-517.
21. Geem, Z.W. (2011). Transport energy demand modeling of South Korea using artificial neural network. *Energy Policy*, 39, 4644-4650.
22. Geem, Z.W. & Roper, W.E. (2009). Energy demand estimation of South Korea using artificial neural network. *Energy Policy*, 37, 4049:4054.
23. Hollnagel, E. (1989). *The reliability of expert systems*, Ellis Horwood Ltd.
24. Huang, C. L., Hsu, T. S. & Liu, C. M. (2009). The Mahalanobis-Taguchi system - Neural network algorithm for data-mining in dynamic environments. *Expert Systems with Applications*, 36, 5475-5480.
25. Javadpour, R. & Knapp, G.M. (2003). A fuzzy neural network approach to machine condition monitoring. *J Computers And industrial engineering*, 45, 323-330.
26. Jung, J. & Yum B. (2011). Artificial neural network based approach for dynamic parameter design. *Expert Systems with Applications*, 38, 504-510.
27. Kermanshahi, B. & Iwamiya, H. (2002). Up to year 2020 load forecasting using neural nets. *Energy Power and Energy Systems*, 24.
28. 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, 271-280.
29. 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.
30. Murat, Y.S. & Ceylan, H. (2006). use of artificial neural networks for transport energy demand modeling. *Energy Policy*, 34, 3165-3172.
31. Pagolatus, J. H. (1986). Demand for Oil Products in USA. *The Iowa Economic Journal*, 38, 128-152.

32. 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.
33. 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.
34. 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 , 1437– 1449.
35. Suganthi, L. & Samuel, A. (2012). Energy models for demand forecasting-A review. *Renewable and Sustainable Energy Reviews*, 16, 1223– 1240.