

توسعه مدل محاسباتی ترکیبی بر پایه شبکه عصبی مصنوعی برای پیش‌بینی تقاضای جهانی گاز طبیعی

رضا حافظی^۱، امیر ناصر اخوان^{۲*}، سعید پاک‌سرشت^۴

^۱ دانش‌آموخته دکتری آینده‌پژوهی دانشکده مدیریت، علم و فناوری، دانشگاه صنعتی امیرکبیر (پلی‌تکنیک)، تهران، ایران

^۲ عضو گروه آینده‌اندیشی، مرکز تحقیقات سیاست علمی کشور، تهران، ایران

r.hafezi@aut.ac.ir

^۳ استادیار دانشکده مدیریت، علم و فناوری، دانشگاه صنعتی امیرکبیر (پلی‌تکنیک)، تهران، ایران

akhavan@aut.ac.ir

^۴ مدیریت پژوهش و فناوری، شرکت ملی گاز ایران، تهران، ایران

pakresesht@nigc.ir

چکیده: از آنجا که سیستم‌های انرژی رفتاری پیچیده از خود نشان می‌دهند همواره مورد توجه پژوهشگران بوده‌اند. از سوی دیگر سیاست‌گذاران حوزه انرژی به دنبال درک بهتر رفتار آتی متغیرهای وابسته به سیستم‌های انرژی جهت پیشینه ساختن سود و احتمال موفقیت راهبردهایشان هستند. در این مقاله، مسئله تقاضای جهانی گاز طبیعی بررسی شد و مدلی ترکیبی بر پایه شبکه عصبی مصنوعی توسعه یافت. در مدل پیشنهادی، ابتدا ورودی‌های معمول پیش‌بینی تقاضای انرژی مطالعه قرار شدند. برای تضمین در نظر گرفتن تمام ورودی‌های محتمل، روش پیشینه مدنظر قرار گرفت و با توجه به امکان دسترسی به داده خام، تعداد زیادی متغیر از جمله متغیرهای منتخب مطالعات پیشین به عنوان ورودی مدل در نظر گرفته شد. با استفاده از ابزارهای داده‌کاوی از ۱۳ ورودی در دسترس، مجموعه ۶ ورودی به عنوان نماینده کل جمعیت شناسایی شده و مدل بر مبنای آن‌ها پیاده‌سازی شد. سپس الگوریتم پیش‌بینی ترکیبی هوشمندی طراحی شد، به نحوی که از الگوریتم ژنتیک برای بهینه‌سازی و آموزش شبکه عصبی مصنوعی استفاده گردید. مطالعه خروجی‌ها نشان داد در مقایسه با مدل‌های پایه و موجود در مطالعات پیشین و با در نظر گرفتن پنج آماره خطای متفاوت، مدل پیشنهادی عملکرد بهتری نسبت به سایر مدل‌ها دارد.

واژه‌های کلیدی: تقاضای گاز طبیعی، پیش‌بینی هوشمند، داده‌کاوی، شبکه عصبی مصنوعی، الگوریتم ژنتیک.

۱. مقدمه

بررسی می‌شود.

اردوگدو [۲] مقاله‌ای بر مسئله تقاضای گاز طبیعی در ترکیه نگارش کرد. در این مقاله اشاره شد که به‌طور میانگین، تقاضای گاز طبیعی در دوره مطالعاتی در کشور ترکیه سالانه حدود ۸٪ رشد دارد؛ این میزان در میان کشورهای جهان قابل توجه است. میزان مصرف گاز طبیعی در یک بازه بیست‌ساله (از ۱۹۸۷ تا ۲۰۰۷) در کشور ترکیه، از ۰/۵ میلیارد مترمکعب به ۳۵ میلیارد مترمکعب رسید. در این مطالعه، نویسنده با استفاده از مدل سری زمانی آریمان^۱ مشخصه‌های تقاضای گاز طبیعی در کشور ترکیه را پیش‌بینی و نتایج را با پیش‌بینی‌های رسمی منتشرشده مقایسه کرد. نتایج نشان داد کاهش تقاضا بسیار پایین است؛ یعنی مصرف‌کنندگان در برابر تغییرات قیمت (به‌ویژه افزایش حساسیت فراوانی نشان نداده و در پاسخ میزان تقاضا را تعدیل نمی‌کنند یا منبع تأمین انرژی خود را تغییر نمی‌دهند) از گاز طبیعی به سایر حامل‌ها).

شافر عوامل مؤثر بر پایداری عرضه گاز طبیعی را مطالعه کرد. محور اصلی این مطالعه سیاست خارجی بوده و نویسنده در این مقاله، ارتباطات و روابط سیاسی و اثر آن بر ساختار عرضه گاز طبیعی را مورد آزمون قرار داده است [۳]؛ همچنین انگیزه دولت‌ها را در ایجاد اختلال در نظام عرضه گاز طبیعی در راستای اهداف و سیاست خارجی را تحلیل کرده است. در واقع ۳۵ رابطه عرضه و ۲ مورد مطالعاتی تحلیل شدند.

اسمیت در پژوهشی، ۲۳ پیش‌بینی مختلف از آینده تقاضای گاز در اتحادیه اروپا را مطالعه کرد [۴]. مقادیر به‌دست‌آمده از این پیش‌بینی‌ها در بسیاری از موارد، تفاوت چشم‌گیری را در مقدار عرضه از منابع (حامل‌های) مختلف نشان می‌داد که نویسنده مدعی می‌شود که نوسانات متأثر از دو عامل کلیدی است: ۱. شدت مصرف انرژی؛ ۲. سهم انرژی هسته‌ای و سوخت‌های تجدیدپذیر از تأمین برق در مقابل سایر منابع.

افزون بر این، بررسی‌ها نشان داد که طبق پیش‌بینی آژانس بین‌المللی انرژی و آمار منتشرشده توسط اتحادیه اروپا از تخمین میزان تقاضای گاز طبیعی در افق ۲۰۲۰ و ۲۰۳۰ میزان تقاضا به‌صورت پیوسته رشد خواهد داشت.

مقاله‌های محدودی نیز به مطالعه عرضه و تقاضای گاز طبیعی در ایران پرداختند. برای نمونه حیدری و همکاران اثر میزان مصرف گاز طبیعی را بر رشد ایران ارزیابی کردند [۵]. یافته این پژوهش نشان داد درآمدزایی و میزان مصرف گاز طبیعی یکدیگر را تقویت می‌کنند و افزایش یکی موجب رشد دیگری خواهد شد. همچنین نویسندگان نشان

همواره بشر در تلاش بوده تا بر مبنای جهان‌آفرینش، الگویی طراحی کند که بتواند حوادث گذشته را توجیه و به‌وسیله آن رویدادهای آینده را پیش‌بینی نماید. از این‌روست که مدل‌سازی در حوزه‌های مختلف از جمله ریاضیات، فیزیک، مهندسی، اقتصاد، مالی و... اهمیت پیدا کرده است. اما پیچیدگی جهان بیرونی به‌قدری است که مدل‌های ساخته‌شده نتوانسته پاسخ‌گوی ظرافت‌های موجود در آن‌ها باشد. بعضی از این مدل‌ها هم تنها در شرایط خاصی جواب‌گوی مسائل هستند.

انرژی همچون سایر عوامل کلان اقتصادی، قابلیت کنترل‌پذیری کمی دارد یا لااقل می‌توان ادعا کرد که بازیگران اندکی در عرصه جهانی قادرند مسیر حرکت روند مبادلات انرژی را تغییر دهند. علاوه بر تأثیرپذیری کم اقتصاد انرژی در سطح بین‌المللی، ویژگی دیگری را نیز می‌توان برای این عامل کلان سیاست‌گذاری برشمرد و آن اینکه اثرات بحران‌ها و شوک‌های ناشی از تغییرات آن به‌گونه‌ای است که عکس‌العمل نشان دادن در قبال آن بسیار پیچیده بوده و برای اثرگذاری نیازمند زمان بسیاری است. به‌طور خاص، ویژگی دوم باعث شده تصمیم‌گیران، تحلیل‌گران و سیاست‌گذاران به تصویرسازی از آینده انرژی رو آورده و در تلاش باشند تا با کشف عوامل مؤثر بر آینده انرژی و رصد تغییرات آن‌ها، تصویری از جهان فردا ارائه دهند. این گرایش در اواسط دهه ۱۹۷۰ میلادی (یعنی حدود ۴۵ سال پیش) به یک الزام در سطح بین‌المللی تبدیل شد. تحریم نفتی غرب توسط کشورهای عربی ادبیات مبادلات نفت و گاز طبیعی را که سهمی عمده در تأمین انرژی و اقتصاد انرژی در دهه‌های اخیر داشته‌اند، دست‌خوش تغییر ساخت. در سال‌های پس از آن و با جلب توجه جهانی به موضوع توسعه پایدار و محدودیت منابع انرژی، گزارش‌های آینده‌نگرانه متعددی در حوزه انرژی و به‌خصوص نفت و گاز منتشر شد. با توجه به سرمایه‌گذاری‌های صورت‌گرفته در میدان‌های گاز طبیعی کشور، توسعه صادرات گاز طبیعی به‌عنوان یکی از راهبردهای کلان ملی مدنظر قرار گرفته است [۱].

در این مقاله، با استفاده از ابزارهای یادگیری ماشین و داده‌کاوی ابتدا متغیرهای اساسی مؤثر بر پیش‌بینی آینده تقاضای جهانی گاز طبیعی شناسایی و سپس مدلی برای پیش‌بینی میزان تقاضای جهانی گاز طبیعی ارائه خواهد شد.

۲. پیشینه پژوهش

در سال‌های اخیر، پیش‌بینی در حوزه مسائل مرتبط با انرژی بسیار مورد توجه پژوهشگران بوده است. در ادامه برخی از پژوهش‌های اخیر

نتایج تحلیل‌ها نشان داد برای کشور ایران نسبت ذخایر به تولید با شیب ملایمی از میانه دهه ۱۹۹۰ میلادی رو به کاهش است (بر اساس آمار اوپک و بریتیش پترولیوم). هرچند چنین تحلیلی دور از ذهن نیست. برای ارائه زاویه دید وسیع‌تر، به‌طور خلاصه در جدول (۱)، دیگر مقاله‌هایی که با هدف تحلیل وضعیت آینده صنایع انرژی ایران نگارش شده‌اند، طبقه‌بندی شده است.

دادند قیمت گاز طبیعی با میزان مصرف آن در کشور، رابطه معکوس دارد. در مطالعه‌ای دیگر، اسین و ارال تغییر در نسبت ذخایر گاز طبیعی به میزان تولید گاز طبیعی^۱ را برای چهار کشور ایران، روسیه، قطر و ترکمنستان بررسی کردند [۶]. اهمیت این مطالعه از جنبه نیاز به انرژی پاک (نگرانی‌های زیست‌محیطی) و نیز توسعه فناوری بوده است. پایه‌های تحلیل نیز بر سیاست‌های ملی و روابط بین‌المللی استوار بود.

جدول (۱): طبقه‌بندی سایر مقاله‌های منتخب که به بررسی صنایع انرژی ایران پرداخته‌اند.

ردیف	سال چاپ	شماره مرجع	توضیحات
۱	۲۰۱۴	[۷]	بررسی اثر استخراج منابع نفتی غیرمتعارف بر شرایط بازار جهانی نفت و ارائه سناریویی بر اساس تحلیل چهار کشور اصلی تولیدکننده (ایران، عربستان، کانادا و ونزوئلا)
۲	۲۰۱۸	[۸]	بررسی سیاست‌های بلندمدت ایران در حوزه امنیت صادرات انرژی
۳	۲۰۱۷	[۹]	بررسی جذابیت منابع انرژی ایران از منظر سرمایه‌گذاری
۴	۲۰۱۷	[۱۰]	ارائه مدل سناریونگاری بر مبنای نقشه‌های شناختی فازی برای شناسایی آینده‌های محتمل تولید نفت ایران
۵	۲۰۱۷	[۱۱]	ارزیابی راهبردهای ملی ایران و ارائه چارچوب جدید سناریونگاری بر اساس شیوه تجدیدنظرشده تحلیل ریخت‌شناسی و بر مبنای تناقض بین اهداف کلان انرژی در کشور

صفحه‌های پیشین، غالباً مدل‌سازی تقاضای انرژی مورد هدف پژوهشگران در پیش‌بینی‌های کمی بوده است. در این پژوهش‌ها مسئله پژوهش ثابت و عبارت است از ارائه مدلی قابل اطمینان و با دقت قابل قبول جهت پیش‌بینی تقاضای آینده انرژی؛ لذا از حیث مرور بر ادبیات توزیع روش‌های استفاده‌شده از اهمیت بیشتری برخوردار است. مقاله‌های متعددی از روش‌های مبتنی بر یادگیری ماشین برای پیش‌بینی تقاضای انرژی استفاده کردند: از جمله شبکه عصبی مصنوعی [۱۲، ۱۴-۱۷]، الگوریتم ژنتیک [۱۲، ۱۸-۲۰]، ماشین‌های بردار پشتیبان [۱۶، ۲۱-۲۳] و سایر روش‌ها.

جدول (۲) مزایا و معایب روش‌های مرسوم پیش‌بینی ارائه‌شده در مقاله‌ها را بررسی می‌کند.

جدول (۲): مزایا و معایب روش‌های پیش‌بینی کمی مرسوم

روش‌ها	ویژگی(ها)
کلاسیک	<ul style="list-style-type: none"> تمرکز بر داده تاریخی نوسانات شدید را به‌خوبی نشان نمی‌دهند. به‌طور عام، برای مطالعه بازار سهام توسعه یافتند. مدل شامل بازخورد برای تنظیم پارامترها نیست.
سری زمانی	<ul style="list-style-type: none"> تمرکز بر داده تاریخی اگرچه نوسانات را به‌خوبی دنبال می‌کنند، نوسانات شدید را نشان نمی‌دهند. از حلقه‌های بازخوردی برای به‌روزرسانی مشخصه‌های مدل استفاده نمی‌کنند.
مدل‌های یادگیرنده	<ul style="list-style-type: none"> تمرکز بر داده تاریخی غالباً می‌توانند الگوی به‌روز نوسانات را آموخته و آن‌ها را پیش‌بینی کنند. از حلقه‌های بازخوردی برای تنظیم مشخصه‌های مدل بهره می‌برند.

در مقابل رویکرد مقاله‌هایی که بررسی شد، رویکرد بدیلی وجود دارد که به‌طور کمی عرضه و تقاضا در بازار انرژی را بررسی می‌کند. این مطالعات بر ارائه مدلی پایدار و قابل اطمینان برای پیش‌بینی عرضه یا تقاضای انرژی تمرکز دارند. برای نمونه، پاناپاکیدیس و داگوماس مدل ترکیبی جدید بر پایه هوش مصنوعی را ارائه دادند [۱۲]. این مدل ترکیبی از چهار مدل پایه، تبدیل موجک^۱، الگوریتم ژنتیک^۲، سیستم تطبیقی استنتاج فازی-عصبی^۳ و شبکه عصبی پیش‌رونده^۴ تشکیل یافته است. مدل بدین صورت کار می‌کند که از تکنیک تبدیل موج برای تجزیه ساختار سری زمانی استفاده می‌شود، سپس الگوریتم ژنتیک پارامترهای ورودی مدل تطبیقی استنتاج فازی-عصبی را بهینه کرده و این مدل برای هر واحد تجزیه‌شده پیش‌بینی متناظر را تولید می‌کند. در نهایت، خروجی این مرحله به‌عنوان ورودی شبکه عصبی پیش‌رونده ارائه شده و شبکه عصبی با تجمیع نتایج پیش‌بینی نهایی را ارائه می‌دهد. به‌طور مشابه، دود و همکاران در مقاله‌ای به ارائه مدل برای پیش‌بینی تقاضای گاز طبیعی پرداختند [۱۳]. این مقاله مطالعه موردی بر اساس داده کشور بنگلادش را شامل می‌شود که نویسندگان از مدل‌های پویای اقتصادسنجی برای رسیدن به این هدف استفاده کردند. از این رو که عرضه انرژی وابسته به سیاست‌ها، روابط بین کشورها، توسعه فناوری و... است (ارجاع به‌مرور بر ادبیات صورت‌گرفته در

1. Reserve/Production ratio (R/P)
2. Wavelet Transform
3. Genetic Algorithm
4. Adaptive Neuro-Fuzzy Inference System
5. Feed-Forward Neural Network

اینجاست که در جهان پیچیده (واقعی)، هیچ دو متغیری از هم مستقل نیستند و فقط در میزان وابستگی و نوع ارتباط از هم متفاوت‌اند. در این مقاله، از ابزارهای داده‌کاوی برای رفع این نقص استفاده شده است. بدین صورت که ارتباط بین بیشینه تعداد متغیر/مشخصه‌های در دسترس شناسایی و از طریق فرایندی یادگیرنده مطالعه می‌شود (فاز پیش‌پردازش داده). متغیرهای ورودی اولیه شناسایی شده بر اساس آمار تاریخی (سری زمانی) در دسترس از طریق وبگاه مؤسسه‌های معتبر بین‌المللی در جدول (۳) خلاصه شده است.

جدول (۳): متغیرهای ورودی اولیه (حاصل بررسی پژوهش‌های پیشین و داده خام معتبر در دسترس)			
ردیف	متغیر	واحد	مرجع
۱	انرژی تجدیدپذیر و هسته‌ای	٪ سهم از کل انرژی مصرفی	نویسندگان
۲	انتشار CO_2	تن سرانه	[۲۴]
۳	انتشار CO_2	کیلو تن	
۴	خالص واردات انرژی	٪ سهم از کل انرژی مصرفی	نویسندگان
۵	مصرف سوخت‌های فسیلی	٪ سهم از کل انرژی مصرفی	[۲۵]
۶	رشد GDP	٪ سالانه	[۳۸-۲۶، ۲۴]
	سرانه GDP	دلار آمریکا	
۸	رشد جمعیت	٪ سالانه	[۲۶، ۲۸-۳۰، ۳۳، ۳۶-۴۵]
۹	جمعیت شهری	نفر	[۲۶ و ۳۲]
۱۰	قیمت طلا	دلار	نویسندگان
۱۱	تولید گاز طبیعی	میلیارد مترمکعب	نویسندگان
۱۲	مصرف نفت خام	میلیون تن	نویسندگان
۱۳	قیمت نفت خام	دلار به ازای هر بشکه	[۲۵، ۲۷، ۳۳]
		(مبنا دلار سال ۲۰۱۳)	[۳۹-۴۱، ۴۶]
۱۴	مصرف گاز طبیعی	میلیارد مترمکعب	متغیر هدف

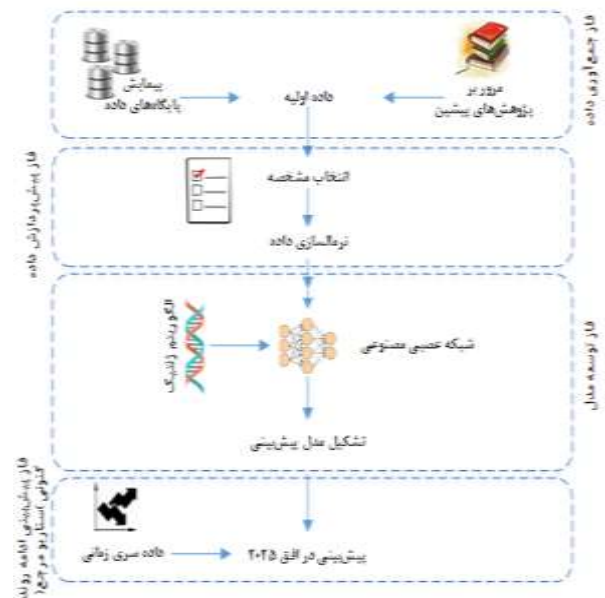
۴. انتخاب مشخصه‌های ورودی

انتخاب ورودی‌ها یکی از مراحل مهم در حل مسائل پیش‌بینی است. به‌طور کلی انتخاب ورودی عبارت است از: تعیین ورودی‌های مرتبط و حذف صفاتی که زاید بوده و اطلاعات اندکی فراهم می‌کنند. گاهی اوقات تجربه قبلی یا ملاحظات نظری به محقق کمک می‌کنند تا مجموعه متغیرهای پیش‌بینی‌کننده را مشخص کند. معمولاً فرایند انتخاب مجموعه‌ای از مشخصه‌ها پیچیده، اما بسیار تأثیرگذار است. تحلیل‌گران عموماً مجموعه‌ای از متغیرهای مستقل پیشنهادی برای شرکت دادن در مدل در ذهن دارند که به احتمال زیاد شامل همه متغیرهای تأثیرگذار است؛ اما مطمئن نیستند که همه این متغیرها به منظور مدل‌سازی مناسب درباره متغیر وابسته (خروجی مدل) لازم باشد.

در این پژوهش، الگویی مبتنی بر شبکه عصبی مصنوعی ارائه شده است که با استفاده از الگوریتم ژنتیک بهینه می‌شود.

۳. روش پیشنهادی

روش شناسایی پیشنهادی پژوهش به صورت مفهومی در شکل (۱) به نمایش درآمده است.



شکل (۱): مدل مفهومی روش شناسایی پژوهش

در فاز اول، به جمع‌آوری داده پرداخته شده است. این فاز اهمیت زیادی دارد؛ زیرا اگر شاخصی مهم مورد غفلت واقع شود، مدل توسعه‌یافته نخواهد توانست آثار مربوط به آن را نمایش دهد؛ از سوی دیگر متغیرهای زاید ممکن است موجب ایجاد انحراف در پاسخ نهایی شوند. به این منظور، مروری بر ادبیات موضوع پیش‌بینی تقاضا در حوزه انرژی انجام شد و متغیرهای اصلی استفاده‌شده در مقاله‌ها استخراج شدند. جدول (۱) خلاصه‌ای از یافته‌های این گام را به همراه مشخصه‌های پیشنهادی نویسندگان ارائه می‌کند.

بر اساس جدول (۱)، مشخصه‌های جی-دی-پی^۱ و جی-ان-پی^۲ جمعیت و قیمت انرژی بسیار پرکاربرد هستند. همان‌طور که ذکر شد، مدل‌های کمی قادر به پیش‌بینی اثرات متغیرهایی که در معادلات ریاضی گنجانده نمی‌شوند نیستند؛ لذا در این مرحله دو محدودیت متناقض وجود دارد: بیشینه کردن تعداد متغیرها برای حصول اطمینان از برون‌یابی اثرات آن‌ها و در مقابل آن، جلوگیری از پیچیده شدن مدل و کاهش قابلیت تفسیرپذیری که به موجب افزایش تعداد متغیرها پدید می‌آید.

به‌طور کلی، یک مدل پیش‌بینی متشکل از یک متغیر هدف (وابسته) و تعدادی متغیر مستقل به‌عنوان عناصر پیش‌بینی‌کننده است. نکته مهم

1. GDP: Gross Domestic Product
2. GNP: Gross National Product

مبنای واحد آن‌ها و تغییر فرم آن به مقادیری بین ۰/۰ و ۱/۰ است. کمترین مقدار (کمینه) روی ۰/۰ و بیشترین مقدار (بیشینه) روی ۱/۰ قرار می‌گیرند و با توجه به میزان فاصله از مقادیر کمینه و بیشینه سایر مقادیر به تناظر عددی بین ۰/۰ و ۱/۰ را به خود اختصاص می‌دهند. این عمل مقایسه داده را نیز تسهیل می‌کند. برای انجام چنین فرایندی از رابطه (۱) استفاده شده است:

$$(1) \quad \text{شده نرمال داده} = \frac{x - \min\{x\}}{\max\{x\} - \min\{x\}}$$

۵. توسعه مدل پیش‌بینی

در این بخش ابتدا مدل‌ها به‌طور اجمالی معرفی و سپس نتایج حاصل از اعمال ورودی‌های نهایی ارائه شده است.

۱.۵. شبکه‌های عصبی مصنوعی

امروزه شبکه‌های عصبی به ابزاری کارآمد و مهم در توسعه سیستم‌های هوشمند در حوزه‌های مختلف تبدیل شده‌اند. تکنیک شبکه‌های عصبی ایده‌ای است که قصد دارد با استفاده از مدل‌های ریاضی و توان کامپیوتری، برخی از جنبه‌های ساده مغز انسان را شبیه‌سازی کند. قابلیت مهم شبکه‌های عصبی یادگیری است. یادگیری در شبکه‌های عصبی مانند انسان، از روی مثال است.

از عوامل مهم در معماری^۵ شبکه‌های عصبی می‌توان به موارد زیر اشاره کرد:

۱. ورودی‌های شبکه (لایه ورودی)^۶
۲. خروجی‌های شبکه (لایه خروجی)^۷
۳. تعداد لایه‌های میانی (لایه پنهان)^۸
۴. چگونگی اتصال لایه‌ها به یکدیگر
۵. تابع تبدیل^۹ هر لایه
۶. تعداد نرون‌های هر لایه

شکل (۲) یک شبکه عصبی مصنوعی را به‌صورت طرح‌واره نشان می‌دهد.

در چنین وضعیتی، غربال کردن متغیرهای ورودی برای توسعه مدلی پایدار پیشنهاد می‌شود. که «بهترین» زیرمجموعه از متغیرهای نسبتاً مستقل را در بر داشته باشد. مدل نهایی باید دارای چنان تعدادی از متغیرها باشد که برای عملکرد رضایت‌بخش آن در کاربردی معین (در اینجا: پیش‌بینی) کفایت کند. از سوی دیگر برای حفظ کمینه بودن هزینه‌های نگهداری مدل، از کمترین تعداد ممکن متغیرهای نسبتاً مستقل استفاده می‌شود. برقرار کردن سازش بین این اهداف متضاد را اغلب، یافتن «بهترین» مدل می‌نامند. اما در بیشتر مسائل، مدلی یگانه که برحسب ضوابط مختلف پیشنهاد شده، «بهترین» باشد وجود ندارد. به‌رغم کمبودهای ذکر شده، انجام فرایند انتخاب ورودی‌ها قبل از به‌کارگیری یک الگوریتم یادگیری دارای مزایای زیر است:

- با حذف تعداد زیادی از ورودی‌های نامربوط، الگوریتم‌های یادگیری هزینه محاسباتی و زمانی کمتری را متحمل می‌شوند.
 - مدلی ساده‌تر با تفسیرپذیری بالاتر به دست می‌آید. چنین مدلی در عمل مفیدتر است. همچنین مدل‌های ساده هنگام به‌کارگیری در مسائل پیش‌بینی، دارای کلیت و عمومیت بیشتری بوده و خروجی‌هایی با دقت بالاتر تولید می‌کنند.
- در این پژوهش، از روش انتخاب مشخصه بر مبنای همبستگی^۱ برای انتخاب بهترین مشخصه استفاده می‌شود که توسط هال^۲ و در سال ۱۹۹۹ ارائه شد [۴۷]. منطق اصلی این روش این است که بهترین مجموعه مشخصه‌ها آن دسته از مشخصه‌ها هستند که بیشترین ارتباط معنادار را با مشخصه هدف دارند و نسبت به یکدیگر مستقل‌اند (کمترین همبستگی بین خودشان). برای بهینه کردن الگوی جست‌وجو از دو متد «بهترین» اولین [۴۸] و «جست‌وجوی گام‌به‌گام» [۴۹] استفاده شد. در نهایت مشخصه/ متغیرهای ورودی انتخاب شده شامل انرژی تجدید پذیر و هسته‌ای، انتشار CO_2 سرانه GDP ، جمعیت شهری، میزان تولید گاز طبیعی و مصرف نفت خام هستند.

۱.۴. نرمال‌سازی داده

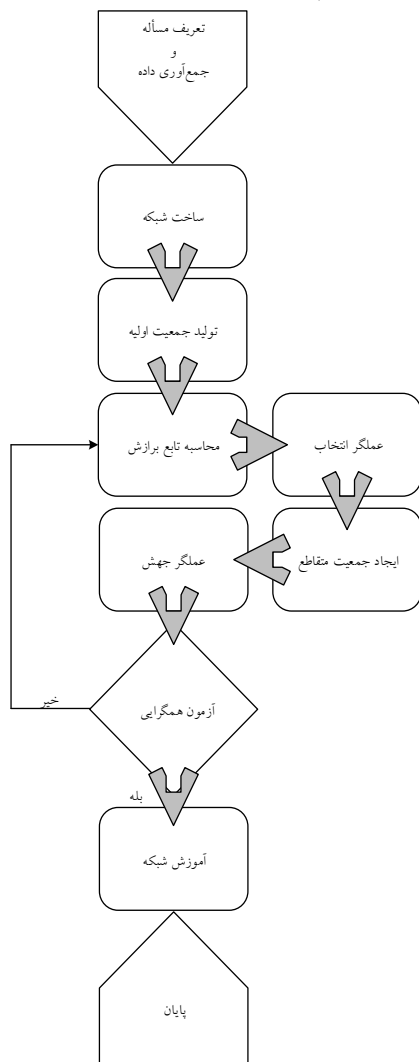
از آنجایی که واحد هر یک از مشخصه‌ها و دامنه تغییراتشان در بسیاری از موارد متفاوت از دیگری است و با توجه به این نکته که مدل‌های یادگیرنده برای داده‌های نرمال عملکرد بهتری از خود نشان می‌دهند، از یکی از شیوه‌های متداول نرمال‌سازی داده در مقاله استفاده و داده به دامنه «صفر» تا «یک» منتقل شد. یک شیوه متداول نرمال‌سازی داده، تبدیل مینیمم-ماکزیمم است، که فرایند دریافت داده مهندسی بر

5. Architecture
6. Input Layer
7. Output Layer
8. Hidden Layer
9. Transformation Function

1. Correlation-based Feature Selection (CFs)
2. Hall
3. Best First
4. Greedy Stepwise

آن‌هایی که فاقد این خصوصیات باشند، به تدریج و در طی زمان از بین می‌روند. در این بین گاهی جهش‌هایی نیز در کروموزوم‌ها روی می‌دهد که ممکن است باعث بهتر شدن نسل بعدی شوند. الگوریتم ژنتیک نیز با استفاده از این ایده، اقدام به حل مسائل می‌کند.

در این مقاله از الگوریتم ژنتیک جهت بهینه‌سازی شبکه عصبی مصنوعی استفاده شده است. شبکه عصبی بهینه‌شده با الگوریتم ژنتیک می‌تواند در زمان انجام محاسبات صرفه‌جویی کند و نیز دقت محاسبات را افزایش دهد [۵۱]. شکل (۳) به اختصار گام‌های بهینه‌سازی شبکه عصبی توسط الگوریتم ژنتیک را نشان می‌دهد.




شکل (۳): طرح‌واره شبکه ژنتیک-عصبی

در ادامه، نتایج پیاده‌سازی مدل پیشنهادی ارائه و نحوه عملکرد و دقت آن مطالعه شده است.

۶. پیاده‌سازی و ارائه نتایج

پیش از ارائه نتایج، پیش‌بینی ساختار بهینه مدل ترکیبی عصبی-ژنتیک توسعه داده‌شده را بررسی می‌شود. تعداد نرون‌های لایه ورودی مشخص



شکل (۲): عناصر اصلی شبکه عصبی مصنوعی

با توجه به کاربردهای متنوع شبکه‌های عصبی در زمینه‌های گوناگون، تفاوت‌هایی در ساختار لایه‌ها و توابع استفاده‌شده در نرون و الگوریتم آموزش آن‌ها وجود دارد که برای اهداف مختلف از ساختارهای متفاوت در شبکه استفاده می‌شود. هنگام روبرو بودن با سیستم‌هایی که رفتار آن‌ها کاملاً پیچیده و درک‌نشده است و فقط اطلاعات عددی از رفتار سیستم در دست است، می‌توان از شبکه‌های عصبی برای مدل‌سازی سیستم استفاده کرد.


از مزایای شبکه‌های عصبی می‌توان به قابلیت یادگیری، قابلیت تعمیم، پردازش موازی (سرعت مناسب)، تحمل‌پذیری در برابر خطا اشاره کرد. از معایب آن‌ها نیز می‌توان به تفسیرپذیری پایین، عدم وجود روشی صریح برای تعیین ساختار مناسب شبکه، تصادفی بودن وزن و بایاس اولیه اشاره کرد.

۵.۱. الگوریتم ژنتیک

الگوریتم ژنتیک^۱ نوع خاصی از الگوریتم‌های تکاملی است که از تکنیک‌های زیست‌شناسی مانند وراثت و جهش برای یافتن جواب بهینه استفاده می‌کند.

الگوریتم ژنتیک اولین بار در دهه هفتاد میلادی توسط جان هالند و برای بهینه‌سازی‌های مهندسی پیشنهاد شد [۵۰]. الگوریتم‌های ژنتیک از اصول انتخاب طبیعی داروین برای یافتن فرمول بهینه جهت پیش‌بینی یا تطبیق الگو استفاده می‌کنند. مسئله‌ای که باید حل شود ورودی است و راه‌حل‌ها بر طبق یک الگو کدگذاری می‌شوند که تابع شایستگی^۲ نام دارد. قانون انتخاب طبیعی بدین صورت است که تنها گونه‌هایی از یک جمعیت ادامه نسل می‌دهند که بهترین خصوصیات را داشته باشند و

1. Genetic Algorithm
2. Fitness Function



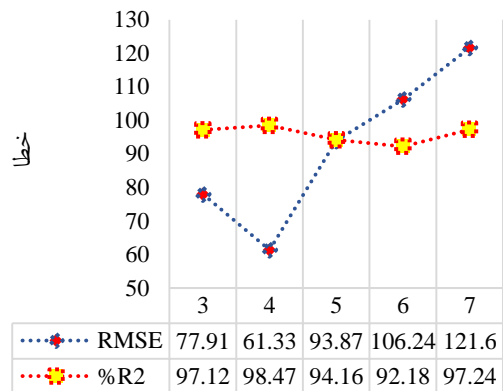
شکل (۵): نتایج پیش‌بینی در بازهٔ آزمون (میانگین ۱۰ بار اجرای مدل)

۷. نتیجه‌گیری

پیش‌بینی رفتار سیستم‌های پیچیده همواره مورد توجه پژوهشگران بوده است. سیستم‌های انرژی از این‌رو که از عوامل متعدد خرد و کلان اعم از اقتصادی، سیاسی، اجتماعی و فناوری تأثیرپذیرند، رفتاری پیچیده و گاهی با عدم قطعیت بالا از خود نشان می‌دهند. ایران به‌عنوان نخستین دارندهٔ منابع گاز طبیعی جهان (حدود ۱۸٪) سهم کمتر از ۱٪ از کل صادرات گاز طبیعی جهان را به خود اختصاص داده است. در سال‌های اخیر و با توجه به کاهش قیمت نفت و طرح ثبات تولید نفت خام در مجموعه کشورهای عضو اوپک، ایران به‌دنبال افزایش سهم خود از بازار جهانی گاز طبیعی و درآمدزایی از طریق فروش گاز طبیعی است. در این مقاله، مسئله تقاضای جهانی گاز طبیعی بررسی شد و مدلی ترکیبی بر پایهٔ شبکهٔ عصبی مصنوعی توسعه یافت.

الگوریتم ژنتیک به‌عنوان الگوی بهینه‌سازی پارامترهای شبکهٔ عصبی پیاده‌سازی شد و خروجی در افق بررسی نشان از دقت مدل پیشنهادی بوده است. برای مقایسهٔ بهتر در این مقاله از مدل‌های مقایسه‌ای سیستم استنتاجی تطبیقی نرو-فازی (آنفیس)، شبکه‌های عصبی پایهٔ شعاعی (آر-بی-اف)، شبکه‌های عصبی مصنوعی رگرسیون عمومی و شبکهٔ عصبی پرسپترون استفاده شد که مدل پیشنهادی با توجه به نتایج حاصل از محاسبهٔ پنج آمارهٔ خطای مختلف، عملکرد بهتری را از خود نشان داد.

و برابر تعداد مشخصه‌های ورودی (۶ تا) خواهد بود، تعداد نرون‌های لایهٔ خروجی هم برابر یک خواهد بود؛ زیرا هدف پیش‌بینی مقدار مصرف/تقاضای گاز طبیعی در سطح جهان است. چالش اصلی شناسایی تعداد نرون‌های بهینه در لایهٔ پنهان است که طبق شکل (۴) و بر اساس آماره‌های خطای آر-دو^۱ و ریشهٔ میانگین مربع خطا^۲ تعداد چهار نرون مقدار بهینهٔ تعداد نرون در ساختار مدل در نظر گرفته شد؛ لذا ساختار شبکه به صورت شش-چهار-یک ساختار بهینه شناسایی شد.



شکل (۴): محاسبهٔ آمارهٔ آر-دو و ریشهٔ میانگین مربع خطا برای ۳، ۴، ۵، ۶ و ۷ نرون در لایهٔ پنهان شبکهٔ عصبی-ژنتیک

شکل (۵) و جدول (۴) نتایج حاصل از آزمون مدل‌های مختلف را روی دادهٔ آزمون (بازهٔ سال‌های ۲۰۰۵ تا ۲۰۱۳) ارائه می‌دهند. برای مقایسهٔ نتایج، مدل‌های دیگری نیز مورد آزمون قرار گرفتند (جدول ۴). سیستم استنتاجی تطبیقی نرو-فازی^۳ (برای مطالعهٔ بیشتر [۵۴-۵۲])، شبکه‌های عصبی پایهٔ شعاعی^۴ (برای مطالعهٔ بیشتر [۵۵ و ۵۶])، شبکه‌های عصبی مصنوعی رگرسیون عمومی (برای مطالعهٔ بیشتر [۵۷ و ۵۸]) و شبکهٔ عصبی پرسپترون (برای مطالعهٔ بیشتر [۵۹]) به‌عنوان مدل‌های مقایسه‌ای در نظر گرفته شدند. پیوست ۲ به‌اختصار، هریک از مدل‌های نام‌برده را شرح می‌دهد. پارامترهای بهینهٔ هریک از مدل‌های مقایسه‌ای از طریق آزمون و خطا بهینه شد. مقدار بهینه و عنوان پارامترهای موجود در هر مدل در جدول (۴) گزارش شده‌اند. برای حصول اطمینان از پایایی نتایج، هر مدل ۱۰ بار مورد آزمون قرار گرفت و نتایج گزارش شده مربوط به میانگین ۱۰ مرتبهٔ آزمون مدل‌هاست. برای نشان دادن وجوه مختلف عملکرد و اعتبارسنجی بهتر مدل پیشنهادی، پنج آمارهٔ مختلف برای محاسبهٔ خطا استفاده شده است (برای اطلاعات بیشتر به پیوست ۱ مراجعه کنید). در ضمن مشخصات بهینه مدل‌های رقابتی طی آزمون «سعی و خطا» حاصل شد.

1. R²
 2. RMSE: Root Mean Squared Error
 3. ANFIS: Adaptive Neuro Fuzzy Inference System
 4. RBF: Radial Basis Function

جدول (۴): مقایسه نتایج به دست آمده از آزمون مدل‌های مختلف بر اساس چند آماره خطای منتخب

عنوان مدل	مشخصات	R ²	MAE	MAPE	MBE	RMSE
مدل پیشنهادی	۴ = تعداد نرون ۱۰۰ = تعداد نسل‌ها ۵ = اندازه جمعیت ۰/۸ = نرخ کراس‌اور ۰/۰۵ = نرخ جهش چرخ رولت = تابع انتخاب وابسته به محدودیت ^۱ = رویکرد جهش وابسته به محدودیت = رویکرد کراس‌اور	۰/۹۸۴۷	۵۲/۱۹	۱/۶۹	۱۳/۵۴	۶۱/۳۳
پرسپترون چندلایه	۲۰۰ = تعداد تکرارها ۱۰ ^{-۷} = شرط توقف در مرحله یادگیری	۰/۸۲۴۱	۱۱۵/۵۹	۳/۸۰	-۴۴/۸۵	۱۴۵/۶۱
انفیس	FCM: رویکرد تولید سیستم استنتاج فازی ۱۰ = تعداد خوشه‌ها ۲ = توان (نما) ماتریس تقسیم‌بندی	۰/۸۴۹۴	۶۳/۴۵	۱/۸۹	۲۱/۳۱	۸۴/۳۱
شبکه‌های عصبی پایه شعاعی	۰/۱۷ = پارامتر (مقدار) انتشار	۰/۰۰۸۱	۳۰۸/۶۴	۱۰/۴۲	-۳۰۸/۶۴	۳۶۶/۵۱
شبکه‌های عصبی مصنوعی رگرسیون عمومی	۱ = پارامتر (مقدار) انتشار	۰/۹۸۶۴	۱۲۷/۶۳	۴/۱۷	-۴/۰۳	۱۴۲/۱۲

پیوست ۱: رابطه مربوط به آماره‌های مختلف برای محاسبه خطا

جدول (۵): رابطه آماره‌های مختلف استفاده شده برای محاسبه خطا در مقاله

عنوان لاتین	مخفف	رابطه
R-squared	R ²	$R^2 = 1 - \frac{SS_{res}}{SS_{tot}}$
Mean Absolute Error	MAE	$MAE = \frac{1}{n} \sum_i f_i - y_i $
Mean Absolute Percentage Error	MAPE	$MAPE = \frac{100}{n} \sum_i \left \frac{f_i - y_i}{y_i} \right $
Mean Bias Error	MBE	$MBE = \frac{1}{n} \sum_i (f_i - y_i)$
Root Mean Square Error	RMSE	$RMSE = \sqrt{\frac{\sum_i (y_i - f_i)^2}{n}}$

$$* SS_{tot} = \sum_i (y_i - \bar{y})^2 \text{ and } SS_{res} = \sum_i (y_i - f_i)^2 = \sum_i (\text{errors})^2$$

1. Constraint Dependent:

این تابع از توابع پیش‌فرض الگوریتم ژنتیک در نرم‌افزار متلب است. الگوریتم عملکرد چنین است که تضمین می‌کند جهت‌های تصادفی تولید شده در هر گام با جواب‌های موجه گام قبل سازگار (منطبق) خواهند بود. الگوریتم استفاده شده در این مقاله در تلاش است محدودیت‌های خطی (طبق اصول پیش‌فرض الگوریتم ژنتیک در نرم‌افزار متلب) را ارضا کند. محدودیت‌ها توسط یک الگوریتم QR (در جبر خطی عددی)، الگوریتم QR رویکردی برای محاسبه مقادیر ویژه و بردار ویژه ماتریس است) که برای تولید مقادیر حدی در مرز موجه محدودیت‌ها ارضا می‌شوند. سپس نقاط تولید شده با خروجی الگوریتم مقایسه می‌شود تا از ارضا تمام محدودیت‌ها اطمینان حاصل شود.

پیوست ۲: شبکه پرسپترون^۱

پرسپترون تک‌لایه ساده‌ترین نوع شبکه عصبی است که از یک لایه از نرون‌های خروجی تشکیل شده است. ورودی‌های این شبکه به‌وسیله یک آرایه از وزن‌ها به‌صورت مستقیم به خروجی‌ها نسبت داده می‌شوند. در نتیجه این شبکه لایه پنهانی ندارد. این شبکه را می‌توان ساده‌ترین شبکه عصبی پیش‌خور دانست. در هر نرون، مجموع ضرب هر وزن در ورودی با اندیس برابر خود محاسبه می‌شود. اگر مقدار مجموع محاسبه‌شده در بالا برای هر نرون بالاتر از یک مقدار آستانه باشد (به‌طور معمول ۰)، نرون فعال شده و مقدار فعال (به‌طور معمول +۱) را می‌پذیرد، در غیر این صورت مقدار غیرفعال (به‌طور معمول -۱) را می‌پذیرد. به نرون‌های با تابع فعال‌سازی از نوع بالا را نرون‌های مصنوعی یا واحدهای آستانه خطی می‌گوییم. اصطلاح پرسپترون اغلب اشاره به شبکه‌های متشکل از تنها یکی از این واحدها می‌کند [۶۰].

یک پرسپترون را می‌توان با استفاده از هر مقداری برای حالت‌های فعال و غیرفعال، تا زمانی که مقدار آستانه بین دو مقدار قرار دارد، ساخت. اکثر پرسپترون‌ها خروجی‌هایی از +۱ یا -۱ با مقدار آستانه ۰ دارند. شبکه‌های دارای ساختار بالا را با سرعت بیشتری نسبت به شبکه‌های متشکل از نرون‌های دارای مقادیر مختلف فعال و غیرفعال، می‌توان آموزش داد [۶۱].

پرسپترون‌ها را می‌توان با یک الگوریتم یادگیری ساده که معمولاً به نام قانون دلتا آن را می‌شناسند، آموزش داد. این الگوریتم خطاهای میان خروجی محاسبه‌شده و خروجی نمونه را محاسبه کرده و از آن برای به‌روزرسانی مقادیر وزن‌ها استفاده می‌کند. این الگوریتم نتیجه اجرای یک نمونه از گرادینان کاهشی است.

پیوست ۳: سیستم استنتاجی تطبیقی نرو-فازی (أنفیس)

نوعی شبکه عصبی مصنوعی است که بر اساس سیستم فازی تاکاگی-سوگنو^۲ است. این شیوه در اوایل دهه ۱۹۹۰ پیشنهاد شد [۶۲ و ۶۳] و برای حل مسائلی که در آن مدل‌سازی ریاضی غیرممکن یا دشوار است (سیستم پیچیده) بسیار مناسب است [۶۴]. از آنجایی که این سیستم، شبکه‌های عصبی و مفاهیم منطق فازی را ترکیب می‌کند، می‌تواند از امکانات هر دو آن‌ها در یک قاب بهره‌برد. سیستم سازگار/تطبیقی آن مطابق با مجموعه قوانین فازی «اگر-آنگاه» است که قابلیت یادگیری برای تقریب زدن توابع غیرخطی را دارد [۶۵ و ۶۶]. همین ویژگی است که باعث شده آنفیس به‌عنوان یک مدل تخمین یونیورسال/جامع^۳ شناخته شود [۶۷].

پیوست ۴: شبکه‌های عصبی پایه شعاعی (آر-بی-اف)

شبکه‌های آر-بی-اف از اقسام شبکه‌های عصبی مصنوعی هستند که ساختارشان از سه لایه تشکیل شده است: لایه ورودی‌ها، لایه پنهان و لایه خروجی [۵۵]. ساختار این شبکه‌ها برخلاف شبکه‌های پرسپترون ثابت است و از این‌روست که آر-بی-اف‌ها را نوع خاصی از شبکه‌های پرسپترون می‌نامند [۶۸]. با وجود ساختار ساده، شبکه‌های آر-بی-اف سرعت و قدرت بالایی در یادگیری دارند که موجب شده به‌صورت گسترده‌ای از آن‌ها استفاده شود [۵۵]. شبکه‌های عصبی پایه شعاعی در تخمین توابع غیرخطی، کلاس‌بندی داده و کنترل سیستم‌ها مورد استفاده قرار گرفته‌اند [۶۹]. با استناد به مقاله نوشته‌شده توسط پارک و سندبرگ می‌توان ادعا کرد که شبکه‌های پایه شعاعی با یک لایه پنهان توانایی تخمین یونیورسال/جامع را دارند [۷۰].

پیوست ۵: شبکه‌های عصبی مصنوعی رگرسیون عمومی

شبکه‌های عصبی رگرسیون عمومی اغلب به‌عنوان توابع تخمین استفاده می‌شوند که شامل یک لایه پایه شعاعی و یک لایه خطی می‌باشند. شبکه عصبی رگرسیون عمومی شبیه به شبکه‌های عصبی پایه شعاعی است که دارای تفاوت‌هایی در لایه پنهان است. این نوع خاص شبکه عصبی مصنوعی اولین بار توسط اسپچ^۴ توسعه داده شد [۷۱]. این نوع شبکه‌ها به‌موجب ویژگی‌هایی که دارند برای تخمین‌های غیرخطی بسیار مناسب‌اند. با توجه به شیوه تخمینی منحصره‌فرد این شبکه‌ها که بر اساس روش‌های رگرسیونی غیر پارامتری است (استفاده از تخمین غیر پارامتری پارزن^۵) نسبت به الگوریتم‌های شبکه عصبی مبتنی بر توابع پایه شعاعی عملکرد سریع‌تری در یادگیری دارد (همگرایی سریع‌تر) [۵۸].

راحتی کار با این دست شبکه‌ها از این جنبه است که تنها یک نوع پارامتر تنظیم‌شونده با عنوان «پارامتر هموارسازی» دارند [۷۲] و از آنجایی که حساسیت مدل به تغییرات کوچک این پارامتر ناچیز است، انتخاب مقدار بهینه آن کار دشواری نیست [۵۷].

1. Perceptron
2. Takagi-Sugeno
3. Universal Estimator

4. Specht
5. Parzen

- [1] Hafezi, R., et al. "A Layered Uncertainties Scenario Synthesizing (LUSS) Model Applied to Evaluate Multiple Potential Long-Run Outcomes for Iran's Natural Gas Exports", Energy, Vol. 169, pp. 646-659, 2018.
- [2] Rdogdu, E., "Natural Gas Demand in Turkey", Applied Energy, Vol. 87, No. 1, pp. 211-219, 2010.
- [3] Shaffer, B., "Natural Gas Supply Stability and Foreign Policy", Energy policy, Vol. 56, pp. 114-125, 2013.
- [4] Smith, W.J., "Projecting EU Demand for Natural Gas to 2030: A Meta-Analysis", Energy policy, Vol. 58, pp. 163-176, 2013.
- [5] Heidari, H., Katircioglu, S.T., and Saeidpour, L., "Natural Gas Consumption and Economic Growth: Are We Ready to Natural Gas Price Liberalization in Iran?", Energy Policy, Vol. 63, pp. 638-645, 2013.
- [6] Esen, V., and Oral, B., "Natural Gas Reserve/Production Ratio in Russia, Iran, Qatar and Turkmenistan: A Political and Economic Perspective", Energy Policy, Vol. 93, pp. 101-109, 2016.
- [7] Matsumoto, K. I., and Voudouris, V., "Potential Impact of Unconventional Oil Resources on Major Oil-Producing Countries: Scenario Analysis with the ACEGES Model", Natural Resources Research, Vol. 24, No. 1, pp. 107-119, 2015.
- [8] Alipour, M., et al., "Long-Term Policy Evaluation: Application of a New Robust Decision Framework for Iran's Energy Exports Security", Energy, Vol. 157, pp. 914-931, 2018.
- [9] Alipour, M., et al. "A New Hybrid Decision Framework for Prioritizing Funding Allocation to Iran's Energy Sector", Energy, Vol. 121, pp. 388-402, 2017.
- [10] Alipour, M., et al., "A New Hybrid Fuzzy Cognitive Map-Based Scenario Planning Approach for Iran's Oil Production Pathways in the Post-Sanction Period", Energy, Vol. 135, pp. 851-864, 2017.
- [11] Hafezi, R., Akhavan, A., and Pakseresht, S., "Projecting Plausible Futures for Iranian Oil and Gas Industries: Analyzing of Historical Strategies", Journal of Natural Gas Science and Engineering, Vol. 39, pp. 15-27, 2017.
- [12] Panapakidis, I.P. and Dagoumas, A.S., "Day-Ahead Natural Gas Demand Forecasting Based on the Combination of Wavelet Transform and ANFIS/Genetic Igorithm/Neural Network Model", Energy, Vol. 118, pp. 231-245, 2017.
- [13] Wadud, Z., et al., "Modeling and Forecasting Natural Gas Demand in Bangladesh", Energy Policy, Vol. 39, No. 11, pp. 7372-7380, 2011.
- [14] Izadyar, N., et al., "Intelligent Forecasting of Residential Heating Demand for the District Heating System based on the Monthly Overall Natural Gas Consumption", Energy and Buildings, Vol. 104, pp. 208-214, 2015.
- [15] Hafezi, R., et al., "A Bat-Neural Network Multi-Agent System (BNNMAS) for Stock Price Prediction: Case Study of DAX Stock Price." Applied Soft Computing, Vol. 29, pp. 196-210, 2015.
- [16] Soldo, B., et al., "Improving the Residential Natural Gas Consumption Forecasting Models by Using Solar Radiation", Energy and buildings, Vol. 69, pp. 498-506, 2014.
- [17] Szoplik, J., "Forecasting of Natural Gas Consumption With Artificial Neural Networks", Energy, Vol. 85, p. 208-220, 2015.
- [18] Askari, S., Montazerin, N., and Zarandi, M.F., "Forecasting Semi-Dynamic Response of Natural Gas Networks to Nodal Gas Consumptions Using Genetic Fuzzy Systems", Energy, Vol. 83, pp. 252-266, 2015.
- [19] Ervural, B.C., Beyca, O.F., and Zaim, S., "Model Estimation of ARMA Using Genetic Algorithms: A Case Study of Forecasting Natural Gas Consumption", Procedia-Social and Behavioral Sciences, Vol. 235, pp. 537-545, 2016.
- [20] Fagiani, M., et al., "A Review of Datasets and Load Forecasting Techniques for Smart Natural Gas and Water Grids: Analysis and Experiments", Neurocomputing, Vol. 170, pp. 448-465, 2015.
- [21] Amasyali, K. and El-Gohary, N., "Building Lighting Energy Consumption Prediction for Supporting Energy Data Analytics", Procedia Engineering, Vol. 145, pp. 511-517, 2016.
- [22] Paudel, S., et al., "A Relevant Data Selection Method for Energy Consumption Prediction of Low Energy Building Based on Support Vector Machine", Energy and Buildings, Vol. 138, pp. 240-256, 2017.
- [23] Zhu, L., et al., "Short-Term Natural Gas Demand Prediction Based on Support Vector Regression With False Neighbours Filtered", Energy, Vol. 80, pp. 428-436, 2015.
- [24] Ramanathan, R., "A Multi-Factor Efficiency Perspective to the Relationships Among World GDP, Energy Consumption and Carbon Dioxide Emissions", Technological Forecasting and Social Change, 73(5): pp. 483-494, 2006.
- [25] Arsenault, E., et al., "A Total Energy Demand Model of Québec: Forecasting Properties", Energy Economics, Vol. 17, No. 2, pp. 163-171, 1995.
- [26] Tolmasquim, M.T., Cohen, C., and Szklo, A.S., "CO2 Emissions in the Brazilian Industrial Sector According to the Integrated Energy Planning Model (IEPM)", Energy Policy, Vol. 29, No. 8, pp. 641-651, 2001.
- [27] Intarapavich, D., et al., "Asia-Pacific Energy Supply and Demand to 2010", Energy, Vol. 21, No. 11, pp. 1017-1039, 1996.
- [28] Raghuvanshi, S.P., Chandra, A., and Raghav, A.K., "Carbon Dioxide Emissions from Coal Based Power Generation in India", Energy Conversion and Management, Vol. 47, No. 4, pp. 427-441, 2006.
- [29] Mackay, R. and Probert, S., "Crude Oil and Natural Gas Supplies and Demands up to the Year AD 2010 for France", Applied energy, Vol. 50, No. 3, pp. 185-208, 1995.
- [30] Parikh, J., Purohit, P., and Maitra, P., "Demand Projections of Petroleum Products and Natural Gas in India", Energy, Vol. 32, No. 10, pp. 1825-1837, 2007.
- [31] Nel, W.P. and Cooper, C.J., "A Critical Review of IEA's Oil Demand Forecast For China", Energy Policy, Vol. 36, No. 3, pp. 1096-1106, 2008.
- [32] Zhang, M., et al., "Forecasting the Transport Energy Demand Based on PLSR Method in China", Energy, Vol. 34, No. 9, pp. 1396-1400, 2009.
- [33] Dincer, I. and Dost, S., "Energy and GDP", International Journal of Energy Research, Vol. 21, No. 2, pp. 153-167, 1997.
- [34] Sözen, A. and Arcaklioglu, E., "Prediction of Net Energy Consumption Based on Economic Indicators

- (*GNP and GDP in Turkey*"), Energy policy, Vol.35, No.10, pp. 4981-4992, 2007.
- [35] Ekonomou, L., "Greek Long-Term Energy Consumption Prediction Using Artificial Neural Networks", Energy, Vol.35, No.2, pp. 512-517, 2010.
- [36] Toksari, M.D., "Ant Colony Optimization Approach to Estimate Energy Demand of Turkey", Energy Policy, Vol.35, No.8, pp. 3984-3990, 2007.
- [37] Ünler, A., "Improvement of Energy Demand Forecasts Using Swarm Intelligence: The case of Turkey With Projections to 2025", Energy Policy, Vol.36, No.6, pp. 1937-1944, 2008.
- [38] Kankal, M., et al., "Modeling and Forecasting of Turkey's Energy Consumption Using Socio-Economic and Demographic Variables", Applied Energy, Vol.88, No.5, pp. 1927-1939, 2011.
- [39] Iniyar, S., Suganthi, L., and Samuel, A.A., "Energy Models for Commercial Energy Prediction and Substitution of Renewable Energy Sources", Energy Policy, Vol.34, No.17, pp. 2640-2653, 2006.
- [40] Suganthi, L. and Jagadeesan, T., "A Modified Model for Prediction of India's Future Energy Requirement", Energy & Environment, Vol.3, No.4, pp. 371-386, 1992.
- [41] Suganthi, L. and Williams, A., "Renewable Energy in India—A Modelling Study for 2020–2021", Energy policy, Vol. 28, No. 15, pp. 1095-1109, 2000.
- [42] Sözen, A., Arcaklioglu, E., and Özkaymak, M., "Turkey's Net Energy Consumption", Applied Energy, Vol.81, No.2, pp. 209-221, 2005.
- [43] Gorucu, F., "Evaluation and Forecasting of Gas Consumption by Statistical Analysis", Energy Sources, Vol.26, No.3, pp. 267-276, 2004.
- [44] Ceylan, H. and Ozturk, H.K., "Estimating Energy Demand of Turkey Based on Economic Indicators Using Genetic Algorithm Approach", Energy Conversion and Management, Vol.45, No.15, pp. 2525-2537, 2004.
- [45] Canyurt, O.E. and Ozturk, H.K., "Application of Genetic Algorithm (GA) Technique on Demand Estimation of Fossil Fuels in Turkey", Energy Policy, Vol.36, No.7, pp. 2562-2569, 2008.
- [46] Persaud, A.J. and Kumar, U., "An Eclectic Approach in Energy Forecasting: A Case of Natural Resources Canada's (NRCan's) Oil and Gas Outlook", Energy policy, Vol. 29, No.4, pp. 303-313, 2001.
- [47] Hall, M.A., "Correlation-Based Feature Selection for Machine Learning", 1999.
- [48] Rich, E. and Knight, K., "Artificial Intelligence", McGraw-Hill, 1991.
- [49] Freitag, D. "Greedy Attribute Selection", in Machine Learning Proceedings, pp. 28-36, 1994.
- [50] Holland, J.H., "Adaptation in Natural and Artificial Systems", University of Michigan Press, Ann Arbor, 1975.
- [51] Zhang, J., et al., "Prediction of LBB Leakage for Various Conditions by Genetic Neural Network and Genetic Algorithms", Nuclear Engineering and Design, Vol.325, pp. 33-43, 2017.
- [52] Anemangely, M., Ramezanzadeh, A., and Tokhmechi, B., "Shear Wave Travel Time Estimation from Petrophysical Logs Using ANFIS-PSO Algorithm: A Case Study From Ab-Teymour Oilfield", Journal of Natural Gas Science and Engineering, Vol.38, pp. 373-387, 2017.
- [53] Zendehboudi, A., X. Li, and Wang, B. "Utilization of ANN and ANFIS Models to Predict Variable Speed Scroll Compressor With Vapor Injection", International Journal of Refrigeration, Vol.74, pp. 473-485, 2017.
- [54] Abdi, J., et al., "Forecasting of Short-Term Traffic-Flow Based on Improved Neurofuzzy Models Via Emotional Temporal Difference Learning Algorithm", Engineering Applications of Artificial Intelligence, Vol.25, No.5, pp. 1022-1042, 2012.
- [55] Fath, A.H., "Application of Radial Basis Function Neural Networks in Bubble Point Oil Formation Volume Factor Prediction for Petroleum Systems", Fluid Phase Equilibria, Vol.437, pp.14-22, 2017.
- [56] Mohammadi, R., Ghomi, S.F., and Zeinali, F., "A New Hybrid Evolutionary Based RBF Networks Method for Forecasting Time Series: A Case Study of Forecasting Emergency Supply Demand Time Series", Engineering Applications of Artificial Intelligence, Vol.36, pp. 204-214, 2014.
- [57] Park, J. and Kim, K.-Y., "Meta-Modeling Using Generalized Regression Neural Network and Particle Swarm Optimization", Applied Soft Computing, Vol.51, pp. 354-369, 2017.
- [58] Hu, R., et al., "A Short-Term Power Load Forecasting Model Based on the Generalized Regression Neural Network With Decreasing Step Fruit Fly Optimization Algorithm", Neurocomputing, Vol. 221, pp. 24-31, 2017.
- [59] Heidari, E., Sobati, M.A., and Movahedirad, S., "Accurate Prediction of Nanofluid Viscosity Using a Multilayer Perceptron Artificial Neural Network (MLP-ANN)", Chemometrics and Intelligent Laboratory Systems, Vol. 155, pp. 73-85, 2016.
- [60] Kasabov, N.K., "Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering", Marcel Alencar, 1996.
- [61] Hagan, M.T., Demuth, H.B., and Beale, M., "Neural Network Design", PWS Publishing Company, USA, Boston, 1996.
- [62] Jang, J.-S.R. "Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm", in AAI, Vol. 91, pp. 762-767, 1991.
- [63] Jang, J.-S., "ANFIS: Adaptive-Network-Based Fuzzy Inference System", IEEE Transactions on Systems, Man, and Cybernetics, Vol. 23, No. 3, pp. 665-685, 1993.
- [64] Lotfinejad, M.M., et al., "A Comparative Assessment of Predicting Daily Solar Radiation Using Bat Neural Network (BNN), Generalized Regression Neural Network (GRNN), and Neuro-Fuzzy (NF) System: A Case Study", Energies, Vol. 11, No. 5, pp. 1188-1203, 2018.
- [65] Abraham, A., "Adaptation of Fuzzy Inference System Using Neural Learning", Fuzzy systems engineering, pp. 914-914, 2005.
- [66] Kamari, A., et al., "Decline Curve Based Models for Predicting Natural Gas Well Performance", Petroleum, Vol. 3, No. 2, pp. 242-248, 2017.
- [67] Jang, J.-S.R., Sun, C.-T., and Mizutani, E., "Neuro-fuzzy and Soft Computing: S Computational Approach to Learning and Machine Intelligence", 1997.
- [68] Schalkoff, R.J., "Artificial Neural Networks", McGraw-Hill Higher Education, 1997.
- [69] Du, D., Li, K. and Fei, M., "A Fastmulti-Output RBF Neural Network Construction Method", Neurocomputing, Vol. 73, pp. 2196–2202, 2010.
- [70] Park, J. and Sandberg, I.W., "Approximation Using

- Radial-Basis-Function Networks*", Neural Computation, Vol. 3, pp. 246-257, 1991.
- [71] Specht, D.F., "A General Regression Neural Network", IEEE Transactions on Neural Networks, Vol. 2, No. 6, pp. 568-576, 1991.
- [72] Hafezi, R., and Akhavan, A., "Forecasting Gold Price Changes: Application of an Equipped Artificial Neural Network", AUT Journal of Modeling and Simulation, Vol. 50, No. 1, pp. 71-82, 2018.