

الگوی پیش بینی تقاضای بنزین در کلان شهر تهران: رویکرد شبکه عصبی مصنوعی

۱ مریم فانی*، ۲ نیما نوروزی

چکیده

در مقایسه با روش‌های معمول، شبکه عصبی مصنوعی (ANN) یکی از ابزار قابل اعتماد برای مدل سازی پدیده‌های پیچیده مانند تقاضا است. هدف از این مطالعه ارائه مدل تقاضای بنزین در بخش حمل و نقل شهری تهران از طریق شبکه عصبی پروپرترون چند لایه و استفاده از مدل ارائه شده در تحلیل حساسیت مدل به متغیرهای ورودی و پیش بینی تقاضای بنزین است. هفت شاخص اجتماعی و اقتصادی در ماه‌های سال‌های ۱۳۸۸ تا ۱۳۹۶ به صورت ماهیانه در نظر گرفته می‌شود: قیمت سوخت، جمعیت، درآمد خانوار متوسط، ضریب جینی، نسبت خودرو نسبت به خودروهای ترکیبی / بنزین، شاخص قیمت کالاها و خدمات و طول عمر وسایل نقلیه. میانگین خطای ۸۸٪ و ۴۶٪ برای داده‌های آموزشی و آزمون به دست آمد. نتایج تجزیه و تحلیل حساسیت نشان داد که نسبت خودروهای ترکیبی / بنزینی $SX6F = -2.580$ جمعیت تهران $SX7F = 0.698$ و میانگین عمر وسایل نقلیه $SX1F = 1.596$ بیشتری بر تقاضای بنزین در بخش حمل و نقل دارند. مصرف سوخت توسط سه سناریوی متفاوت متوسط، بدبین و خوش بینانه تا سال ۲۰۲۲ پیش بینی شده است. نتایج پیش بینی شده نشان می‌دهد که در صورت ادامه روند فعلی متغیرهای توصیفی مدل، تقاضای بنزین در بخش حمل و نقل تهران تا سال ۲۰۲۲ افزایش خواهد یافت.

تاریخ دریافت:

۱۳۹۸ / ۳ / ۱۷

تاریخ پذیرش:

۱۳۹۸ / ۵ / ۲۵

کلمات کلیدی:

تقاضای بنزین، شبکه عصبی مصنوعی، تحلیل حساسیت، پیش بینی تقاضا

۱. مقدمه

تقاضا برای انرژی در اشکال مختلف، از جمله سوخت‌های فسیلی، در بسیاری از جنبه‌های جوامع مانند اقتصادی، اجتماعی و سیاسی نقش مهمی دارد. در این راستا، مدل سازی و پیش بینی مصرف انرژی به طور کلی و سوخت‌های فسیلی به طور خاص، اهمیت بیشتری به دست می‌دهد. پدیده‌هایی مانند آلودگی هوا در مناطق شهری به طور مستقیم تحت تاثیر مصرف سوخت‌های فسیلی قرار دارند. در عین حال، حمل و نقل شهری بخش مهمی از مصرف سوخت فسیلی در شهرهای پرجمعیت است. بنابراین، ارائه یک مدل مناسب که می‌تواند تغییرات در مصرف سوخت در این بخش را پیش بینی کند، ضروری به نظر می‌رسد. به منظور تجزیه و تحلیل تقاضای انرژی و تعیین تأثیر عوامل مختلف، از روشها و ابزارهای مختلف استفاده شده است. اکثر تحقیقات انجام شده برآورد تقاضای بنزین از طریق عملکرد خطی و روش‌های اقتصاد سنجی بود (Suganthi and Samuel, ۲۰۱۲). با این حال، از آنجا که متغیرهایی که بر تقاضای حامل انرژی تأثیر می‌گذارند، در دوره سری زمانی مورد مطالعه فرار هستند، روش‌های غیر خطی می‌توانند برآوردهای بهتر برای مصرف انرژی ارائه دهند (Kubat, ۲۰۱۵).

پدیده‌های کاملاً غیر خطی مانند مصرف سوخت بسیار پیچیده هستند و تحت تأثیر عوامل مختلفی قرار می‌گیرند که هر کدام از آنها رفتار پیچیده‌ای را نشان می‌دهند. به همین دلیل، مدل سازی از طریق روش تحلیل برای این پدیده‌ها غیرممکن است. برای مدل سازی چنین پدیده‌ها، به طور سنتی، تکنیک‌های آماری و مدل سازی رگرسیون، و اخیراً، روش‌های مبتنی بر هوش مصنوعی مانند ANNs استفاده می‌شود. مزیت استفاده از شبکه‌های عصبی در توانایی آنها برای شناسایی و تعیین رابطه بین متغیرهای ورودی و خروجی بدون نیاز به دانش جامع از فیزیک پدیده (Kubat, ۲۰۱۵) است.

مطالعات متعددی، کارایی بهتر و خطای کمتر شبکه‌های عصبی را نسبت به روش‌های سنتی گزارش کرده‌اند. در این مطالعه، یک شبکه چند عاملی پیشگیرنده پیشگیرنده شبکه عصبی با لایه مخفی برای ارائه یک مدل مصرف بنزین در بخش حمل و نقل شهری تهران با توجه به قیمت واقعی سوخت، جمعیت، درآمد خانواده متوسط شهری، ضریب جینی، شاخص قیمت کالاهای مصرفی و خدمات، میانگین

عمر خودرو، نسبت خودروهای ترکیبی به بنزین و ماه سال است. این مطالعه بر روندهای آینده مصرف بنزین در بخش حمل و نقل، همچنین بر تحلیل حساسیت تمرکز دارد.

با توجه به رشد روز افزون مصرف انرژی در بخش حمل و نقل شهری و چالش‌های موجود در تقاضای سوخت و نیز سهم قابل توجه بخش حمل و نقل در آلودگی محیط زیست در شهرهای، تجزیه و تحلیل مصرف سوخت در این بخش و ارزیابی عوامل موثر بر آن، توجه بسیاری از محققان. صادقی و همکاران (۲۰۰۹) برآورد، پیش بینی و بررسی تقاضای بنزین در بخش حمل و نقل شهری ایران از مدل‌های معادلات خطی، معادلات درجه دوم و معادله ای و بر اساس معیارهای معمول استفاده کرده‌اند. در یک مطالعه دیگر، با استفاده از مدل لجستیک تعدادی از وسایل نقلیه، مدل سازی تقاضای نفت در بخش حمل و نقل ایران براساس میزان مصرف سوخت در هر وسیله نقلیه (Mazraati, ۲۰۰۷) ارائه شده است. همچنین در مطالعه دیگری در ایران، شاکری و همکاران (۲۰۱۰) میانگین سن خودروها و تأثیر آن بر مصرف سوخت را بررسی کرده‌اند. غدیری و میرجلیلی (۲۰۰۵) مدل ساختار تقاضای بنزین و دیزل در بخش حمل و نقل در ایران را با استفاده از مدل سری زمانی ساختاری برای دوره زمانی ۱۹۷۹-۲۰۰۷ ارزیابی کردند.

نوروزی و سلگی (۲۰۰۶)، مطالعات مورد نیاز بنزین و عوامل موثر بر آن را مورد مطالعه قرار دادند. در این راستا، تقاضای بنزین در طی یک دوره زمانی از مدل تعدیل جزئی استفاده شده است و کشش کوتاه و بلند مدت آن محاسبه شده است. نتایج این تحقیق نشان می‌دهد که رشد اقتصادی، رشد جمعیت، موجودی وسایل نقلیه، چرخه حمل و نقل کمبودی و ساختار غیر فنی در خیابان‌ها بعضی از عوامل موثر بر تقاضای بنزین است. سقوط و ساموئل (۲۰۱۲) اثر سناریوهای مختلف قیمت را بر میزان مصرف بنزین بررسی کرده‌اند. در این مطالعه، ۹ مدل با توجه به قیمت واقعی بنزین، درآمد واقعی، موجودی وسایل نقلیه و متغیرهای کارایی برآورد شده است. روش برآورد ARDL برای تخمین مدل‌ها استفاده شده است و نتایج نشان داد که بنزین دارای خواص نامطلوب و ضروری است به طوری که با افزایش قیمت در یک سال و ثبات قیمت در سال‌های آتی، مصرف، با یک کاهش در سال افزایش قیمت، در سال‌های آینده همچنان رشد می‌کند.

شبکه‌های عصبی مصنوعی به عنوان یکی از ابزارهای پیش بینی کننده مصرف انرژی مورد استفاده قرار می‌گیرند و با سایر تکنیک‌های مدل سازی مقایسه می‌شوند (Jebaraj and Iniyar, ۲۰۰۶)؛

Limanond et al. (۲۰۱۱). الغندور و همکاران (۲۰۱۲)، تقاضای انرژی تایلند در بخش حمل و نقل را از طریق شبکه‌های عصبی مصنوعی و مدل رگرسیون غیر خطی برای بیست سال آینده پیش بینی کرده‌اند. نصر و همکاران (۲۰۰۳) مدل مصرف انرژی بخش حمل و نقل در اردن و آن را از طریق شبکه عصبی فازی عصبی پیش بینی کرده‌اند. مدل مصرف سوخت در اردن با استفاده از شبکه عصبی برگشتی و چهار نوع شبکه‌های عصبی مورد بررسی و مقایسه قرار گرفته است. در مطالعه دیگری، مورات و سیلان (۲۰۰۶)، استفاده از شبکه‌های پیشرو در حمل و نقل را با استفاده از الگوریتم‌های آموزشی برگشت عقب در مدل سازی مصرف انرژی نشان داده اند و کارایی این روش برای پیش بینی مصرف انرژی در این بخش با نتایج این تحقیق تایید شده است. Aydinalp-Koksal و Ugursal (۲۰۰۸) از شبکه‌های عصبی مصنوعی برای تخمین و مدل سازی مصرف انرژی در بخش خانگی استفاده می‌کنند و با روش‌های دیگر مقایسه می‌شوند. شبکه‌های عصبی نیز در مدل سازی مصرف سوخت در سایر بخش‌ها مانند کشاورزی (Safa و Samarasinghe، ۲۰۱۱) و نیز سایر انواع انرژی مورد استفاده قرار می‌گیرند (Ermis et al.، ۲۰۰۷). تقاضای انرژی کره جنوبی مدل شده و پیش بینی شده است با استفاده از شبکه‌های عصبی مصنوعی با ساختار مشابه با روش ارائه شده در این مطالعه (Roper و Geem، ۲۰۰۹).

توانایی شبکه‌های عصبی مصنوعی برای برآورد توابع غیر خطی پیچیده، آنها را یک ابزار مفید برای مدل سازی پدیده‌های پیچیده است. شبکه‌های عصبی با الهام از سیستم عصبی موجودات زنده، قادر به انجام وظیفه شناسایی الگوهای و میزان و نوع وابستگی متغیرهای ورودی و خروجی می‌باشند (Haykin، ۲۰۰۹؛ Hornik et al.، ۱۹۸۹؛ Leshno et al.، ۱۹۹۳). در سال‌های اخیر، بر خلاف معرفی زود هنگام شبکه‌های عصبی، با استفاده از این ابزارها در حوزه‌های مختلف تحقیق، تجارت و آموزش به طور گسترده مورد توجه قرار گرفته است.

در این تحقیق، متغیرهای توصیفی مدل نسبت به سایر مطالعات بیشتر است. بررسی تاثیر مصرف سوخت مصرفی از متغیرهایی مانند درآمد خانواده متوسط شهری و ضریب جینی در این مطالعه برای اولین بار انجام شده است. در مطالعه موردی اخیر در مورد آلودگی هوا در ایران و تهران، داده‌ها به صورت سالانه اندازه گیری می‌شوند. فاصله زمانی کاهش می‌یابد و به صورت ماهانه در این تحقیق ثبت و مورد مطالعه قرار می‌گیرد. این مسئله علاوه بر افزایش داده‌ها می‌تواند به بهبود کارایی شبکه عصبی منجر

شود. در این مطالعه، مدل شبکه عصبی مصرف سوخت در تهران برای تحلیل حساسیت برای اولین بار مورد استفاده قرار می‌گیرد.

۲. مبانی نظری

متغیرهای اجتماعی و اقتصادی مختلف در تقاضای و مصرف سوخت دخیل هستند. در این مدل، متغیرهای واقعی قیمت سوخت، اندازه جمعیت، درآمد خانواده متوسط شهری، ضریب جینی و شاخص قیمت کالاها و خدمات مصرفی به عنوان متغیرهای اجتماعی و اقتصادی و میانگین عمر وسایل نقلیه به عنوان شاخص از کارایی، به عنوان یک ورودی مستقل در نظر گرفته شده است. اندازه جمعیت، به عنوان شاخص حجم، نیازمند حمل و نقل است و به طور مستقیم در تعیین تقاضای نهایی درگیر است. با افزایش درآمد متوسط شهری شهروندان از استانداردهای بالای زندگی لذت خواهند برد و از وسایل نقلیه بیشتری برخوردار خواهند شد. در نتیجه، تمایل آنها به استفاده از سیستم حمل و نقل عمومی می‌تواند کاهش یابد که تأثیر زیادی بر میزان سفرهای شهری و تقاضای سوخت دارد (نصر و همکاران، ۲۰۰۳). در این مورد، نقش شاخص شاخص توزیع ثروت، هزینه سوخت مورد نیاز و سایر هزینه‌های خانوار باید مورد توجه قرار گیرد. در این مطالعه، ضریب جینی، قیمت واقعی سوخت و شاخص قیمت کالاها و خدمات مصرفی در مناطق شهری ایران که توسط بانک مرکزی ایران محاسبه و منتشر شده است ("بانک اطلاعاتی سری زمانی اقتصادی CBI")، برای این منظور انتخاب شده است. علاوه بر متغیرهای فوق، با توجه به معرفی گاز طبیعی فشرده به عنوان سوخت جایگزین در سال‌های اخیر (Moore et al., ۲۰۱۴)، نسبت تعداد وسایل نقلیه هیبریدی به بنزین متغیر دیگری است که به عنوان ورودی در نظر گرفته می‌شود.

علاوه بر عوامل فوق، رفتار ترافیکی جمعیت شهری، تغییرات در ماهها و فصول مختلف سال، عدم فعالیت مدارس و دانشگاهها در تابستان، هوای سرد و آلودگی هوا در زمستان و سفرهای حومه شهر نوروز، از جمله مواردی است که میتواند بر میزان حمل و نقل شهری و در نتیجه تقاضای سوخت تأثیر می‌گذارد. با توجه به فراوانی ماهانه داده‌های جمع آوری شده، می‌توان اثرات ذکر شده را نادیده گرفت. با استفاده از قدرت شبکه‌های عصبی در تشخیص الگوهای و روابط غیر خطی و پیچیده، تعداد ماه سال به عنوان ورودی مناسب برای نشان دادن چنین تغییراتی استفاده شده است. پارامترهای ورودی در جدول ۱ ذکر شده است.

جدول ۱ متغیرهای توصیفی مدل

واحد	تعریف	پارامتر
نفر	جمعیت شهری تهران	X_1
ریال بر لیتر	قیمت واقعی بنزین	X_2
۱۰۰۰ ریال بر سال	متوسط درآمد خانوار شهری	X_3
بی واحد	ضریب جینی	X_4
بی واحد	شاخص قیمت کالاهای مصرفی و خدمات	X_5
بی واحد	نسبت خودروهای هیبریدی به بنزینی	X_6
سال	متوسط عمر وسایل نقلیه	X_7
بی واحد	ماه سال	X_8

۳. شبکه عصبی مصنوعی

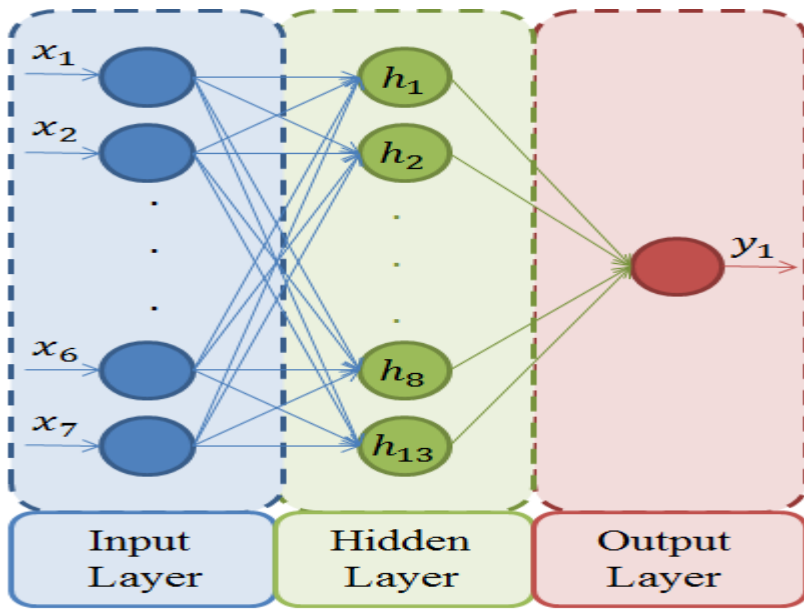
ساختار شبکه‌های عصبی به طور کلی از تعداد معینی از نورون‌ها در لایه‌هایی با تنظیمات مختلف و رشته‌های ارتباطی است که به نام سیناپس در ادبیات سیستم عصبی نامیده می‌شوند، که ارتباط بین نورون‌ها را فراهم می‌کند. هر سیناپس به عنوان وزن سیناپس ارزش دارد که با توجه به وزن آن، خروجی نورون را به ورودی نورون دیگر (Kubat, ۲۰۱۵) منتقل می‌کند.

شبکه عصبی برای طیف گسترده‌ای از برنامه‌ها و مسائل توسعه یافته است. شایع‌ترین شکل از شبکه‌های عصبی مصنوعی برای تطابق عملکردهای پیچیده و پدیده‌های مدل‌سازی با چنین رفتار، نوعی از شبکه عصبی فیدرجری است که به نام پریتروسون چند لایه با تابع فعال‌سازی غیر خطی نامیده می‌شود. این نوع شبکه عصبی، تعداد نورونهای لایه میانی را فراهم می‌کند، قادر به تقریب هر عملکرد مداوم با دقت دلخواه است (Haykin, ۲۰۰۹). ساختار این شبکه از یک لایه ورودی، یک لایه خروجی و برخی لایه‌های مخفی تشکیل شده است. هر یک از نورونهای هر لایه به تمام نورونهای لایه بعدی متصل می‌شود به طوری که خروجی هر نورون با وزن هر سیناپس خروجی متصل به آن ضرب می‌شود و به لایه بعدی منتقل می‌شود. همچنین، در ورودی نورون‌ها، سیگنال‌های دریافت شده برای اولین بار با هم جمع می‌شوند. سپس آنها را به تابع فعال‌سازی نورون وارد می‌کنند و خروجی آن را مشخص

می‌کنند. در این نوع شبکه، عملکرد مداوم غیر خطی و محدود از بالا و محدود از پایین به عنوان تابع فعال سازی استفاده می‌شود. با توجه به اینکه تعداد لایه‌ها بر روی این توانایی شبکه اثر نمی‌گذارد و تنها لایه میانی کافی است، شبکه عصبی پرسترن با یک لایه مخفی در این مدل استفاده می‌شود.

پس از انتخاب نوع شبکه مناسب برای مدل دلخواه، تهیه شبکه‌های عصبی اغلب نیاز به تعیین مقادیر وزن سیناپس خود را بر اساس داده‌های مورد مطالعه دارد. فرایند جستجو برای پیدا کردن وزن مطلوب برای شبکه فاز "آموزش" نامیده می‌شود. به طور معمول، بخشی از داده‌های موجود برای آموزش شبکه استفاده می‌شود، و دیگری برای آزمایش کارایی شبکه عصبی استفاده می‌شود. یکی از روش‌های رایج برای آموزش شبکه‌های پیشنهادی، "الگوریتم انتشار خطای عقب" است (Kubat, ۲۰۱۵).

مقادیر اولیه وزن سیناپسی به طور تصادفی بین -۱ و ۱ انتخاب شده است. مماس‌های هیبربولی برای تابع فعال سازی شبکه انتخاب شده‌اند. در آموزش شبکه عصبی، انتخاب مناسب برای ضریب تمرین برای دستیابی به پاسخ مطلوب ضروری است. در آموزش شبکه عصبی MLP، ضریب آموزش لایه‌های مختلف می‌تواند متفاوت باشد. به منظور جلوگیری از نوسانات در شبکه در مورد پاسخ بهینه، ضریب یادگیری لایه خروجی معمولاً کمتر از لایه‌های دیگر انتخاب می‌شود. چنین رویکردی نیز در این مدل اتخاذ شده است و ضریب یادگیری برای آخرین لایه انتخاب شده برابر با نیمی از ضریب لایه پنهان است. پارامترهای شبکه عصبی مصنوعی معمولاً به روش آزمایش و خطا (Kubat, ۲۰۱۵) تنظیم می‌شوند. تعداد نورون‌های پنهان لایه با توجه به پیچیدگی داده‌ها و توسط کارشناسان در یک روش تجربی انتخاب شد و تعداد نورون‌ها با توجه به پاسخ شبکه به صورت جدول ۲ نشان داده شد. مقادیر نهایی انتخاب شده برای پارامترهای مختلف شبکه در جدول ۳ نشان داده شده است. ساختار ANN انتخاب شده در شکل ۱ نشان داده شده است.



شکل ۱ ساختار ANN انتخاب شده

جدول ۲ انتخاب تعداد گره‌های پنهان

خطای داده‌های آزمون (%)	خطای داده‌های آموزش ^۱ (%)	تعداد نورونهای پنهان
18.1	15.1	9
19.5	14.9	10
13.4	11.0	11
9.1	8.7	12
6.4	5.5	13
(APE) متوسط میزان خطا ^۱		

جدول ۳ بهترین مشخصات ANN انتخاب شده

0.0075	تراز آموزش
0.5	ضریب مومنتوم
13	تعداد نورونهای پنهان
تانژانت هیپربولیک	تابع فعال سازی

۴. توصیف داده ها

داده‌های ورودی شامل سال‌های ۱۳۹۰ تا ۱۳۹۵ (برنامه توسعه پنجم) و فرکانس آنها به صورت ماهانه می‌باشد. برای جمع‌آوری داده‌ها، کتاب اطلاعات حمل و نقل کشور ("وزارت صنایع، معادن و تجارت")، ترازنامه انرژی ("جدول تراز انرژی ایران")، ترازنامه نفتی هیدروکربنی ("جدول تراز هیدروکربنی ایران")، سالنامه آماری کشور ("سالنامه آماری ایران") در رابطه با سال‌های ذکر شده و بانک اطلاعات مرکزی بانک اطلاعاتی جمهوری اسلامی ایران ("بانک اطلاعاتی سری زمانی اقتصادی CBI") استفاده شده است.

البته داده‌های یاد شده در منابع به صورت سالانه درج شده اند ولیکن برای مدلسازی رفتار ماهانه باتوجه به موجود بودن داده‌های فصلی در منابع یاد شده برای مثال داده‌های بانک مرکزی و بانگاهی بر بانک جهانی نرخ رشد فصلی محاسبه شده و با توزیع نرمال بر روی ماه‌های فصل پخش شده که با توجه به رفتار مشابه رشد بسیاری از شاخص‌ها که قسمت اعظم رشد یا تغییر متغیر در روزهای میانی فصول رخ می‌دهد این توزیع می‌تواند روش مناسبی برای تولید داده‌های ماهانه باشد. دلیل استفاده از این روش عدم وجود داده‌های کافی و نیازمندی به وجود مدلی جامع برای پیش‌بینی کاربردی میزان تقاضا برای بنزین کر کلانشهر تهران می‌باشد. علاوه بر عوامل فوق، رفتار ترافیکی جمعیت شهری، تغییرات در ماهها و فصول مختلف سال، عدم فعالیت مدارس و دانشگاهها در تابستان، هوای سرد و آلودگی هوا در زمستان و سفرهای حومه شهر نوروز، از جمله مواردی است که میتواند بر میزان حمل و نقل شهری و در نتیجه تقاضای سوخت تاثیر می‌گذارد. با توجه به فراوانی ماهانه داده‌های جمع‌آوری شده، می‌توان اثرات ذکر شده را نادیده گرفت.

۱۰ درصد از داده‌ها به صورت تصادفی انتخاب شده و به عنوان داده‌های آزمون برای اعتبار سنجی کارایی مدل مورد استفاده قرار می‌گیرند و بقیه داده‌ها برای آموزش شبکه عصبی مورد استفاده قرار می‌گیرند. از آنجا که شبکه‌های عصبی برای استخراج داده‌های آموزشی استفاده نمی‌شوند، اطمینان حاصل شد که داده‌های آزمون حداکثر و حداقل امتیاز را شامل نمی‌شود. برای نشان دادن مقیاس متغیرهای ورودی، برخی از داده‌ها در جدول ۴ ذکر شده‌اند.

جدول ۴ برخی از مجموعه داده ها

X_1	X_2	X_3	X_4	X_5	X_6	X_7
7761526	2010	53678	0.402	39.70	0.003	11.904
7820278	1794	62029	0.401	41.80	0.012	11.520
7886008	1898	72792	0.403	48.80	0.031	11.158
7956979	1513	83959	0.394	60.60	0.075	10.838
8028564	1366	91360	0.391	70.00	0.123	10.577
8100836	3038	100925	0.387	77.20	0.161	10.366
8173816	5500	120241	0.378	93.10	0.193	10.233
8247497	4215	113373	0.380	112.90	0.217	10.447
8307332	3127	141441	0.382	160.50	0.233	10.836

داده‌های مورد بررسی قبل از اعمال به شبکه عصبی نیاز به پیش پردازش برای یادگیری دارند، به طوری که میانگین هر مجموعه داده ورودی باید نزدیک به صفر یا کوچک باشد در مقایسه با انحراف استاندارد (Leshno et al., ۱۹۹۳). میانگین هر مجموعه ای از داده‌ها از مقدار آن محاسبه شد. همچنین لازم است که انحراف استاندارد داده‌ها به حد ممکن نزدیک به یکدیگر باشد. برای این منظور داده‌ها به درستی اندازه گیری شده‌اند. لازم به ذکر است که این عملیات باید هنگام استفاده از شبکه عصبی برای مجموعه جدید داده‌ها تکرار شود. علاوه بر این، با توجه به اینکه تابع فعال سازی لایه خروجی مشابه شبیه لایه پنهان و عملکرد sigmoid انتخاب می‌شود، مقیاس داده خروجی نرمال شده باید به گونه ای انتخاب شود که داده‌ها در محدوده عملکرد فعال (Kubat, ۲۰۱۵) علاوه بر این، لازم است که محدوده داده‌های خروجی در رابطه با محدوده عملکرد فعال سازی لایه خروجی جبران شود.

در این مطالعه متغیرها به صورت زیر استفاده شده اند:

پارامتر اول: جمعیت شهری تهران براساس نفر که در طی هشت سال انحراف از معیار بالایی را تجربه کرده است که این خود به دلیل سیاست گذاری‌های اشتباه و میزان بالای مهاجرت از شهرهای مختلف به خصوص شهرهای حاشیه ای به این شهر می‌باشد. این متغیر به عنوان پارامتر اصلی درگیر تعیین کننده حجم نیاز به حمل و نقل است.

پارامتر دوم: قیمت واقعی بنزین یا میزان واقعی توان خرید بنزین و استفاده از بنزین نسبت به دیگر کالا و خدمات نیز می‌تواند بیانگر ارزش واقعی این کالا و میزان دسترسی مردم به این سوخت باشد. که

عاملی مهم در تعیین تقاضای سوخت است و واحد آن ریال بر لیتر می‌باشد. که در طی سال‌های گذشته به دلیل دخالت‌های دولتی انحراف از معیار بسیار شدیدی را تجربه نموده است.

پارامتر سوم: میزان متوسط درآمد خانوار شهری بر حسب ۱۰۰۰ ریال بر سال که بیانگر این است که با افزایش درآمد متوسط شهری شهروندان از استانداردهای بالای زندگی لذت خواهند برد و از وسایل نقلیه بیشتری برخوردار خواهند شد. در نتیجه، تمایل آنها به استفاده از سیستم حمل و نقل عمومی می‌تواند کاهش یابد که تأثیر زیادی بر میزان سفرهای شهری و تقاضای سوخت دارد.

پارامتر چهارم: ضریب جینی که شاخصی برای توزیع درآمد هست می‌تواند به دلیل بیان مفهوم مناسبی از تجمع امکانات در درصدی از جمعیت که عموماً تمایلی به استفاده از حمل و نقل عمومی ندارند، میزان جمعیت متمایل به حمل و نقل عمومی و در نتیجه موثر در تقاضای بنزین را مشخص نماید.

پارامتر پنجم: ضریب شاخص هزینه کالا و خدمات که شاخصی برای توزیع هزینه‌ها است می‌تواند به دلیل بیان مفهوم مناسبی از میزان هزینه‌های خانوار و مشخص کردن میزان هزینه برای سوخت و همینطور میزان پول باقی مانده برای خری یا استفاده از عوامل مصرف کننده بنزین به عنوان پارامتری مهم در پیشبینی تقاضای سوخت استفاده شود.

پارامتر ششم: علاوه بر متغیرهای فوق، با توجه به معرفی گاز طبیعی فشرده به عنوان سوخت جایگزین در سال‌های اخیر، نسبت تعداد وسایل نقلیه هیبریدی یا دوگانه سوز به خودروهای بنزین متغیری مهم است که به عنوان ورودی در نظر گرفته می‌شود.

پارامتر هفتم: متوسط عمر ناوگان حمل و نقل به ویژه حمل و نقل عمومی و فناوری مورد استفاده در این ساختار از جمله عوامل بسیار مهم بر تقاضای مصرف سوخت هست که میتواند بر کاهش یا افزایش شدید مصرف سوخت و تغییرات تقاضا بسیار اثرگذار باشد. البته این متغیر رفتار فصلی نداشته و نرخ تغییرات سالانه آن ثابت است. البته باید گفت که انحراف از معیار کم این پارامتر نشان از بی توجهی تاریخی به این پارامتر بسیار مهم در صنعت حمل و نقل و خودرو سازی کشور است.

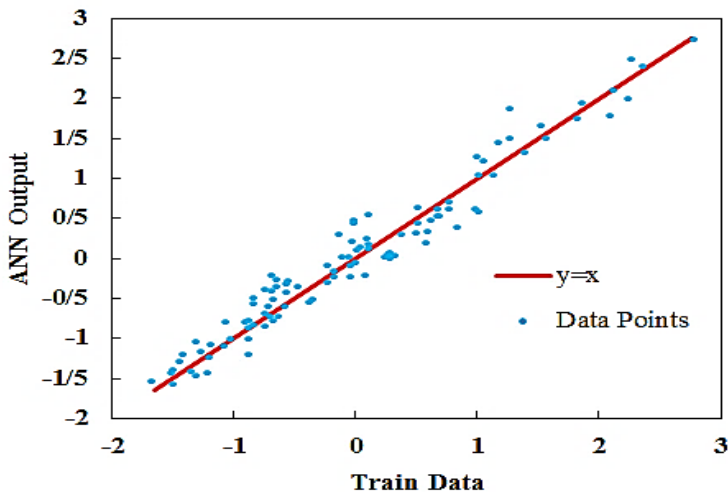
پارامتر هشتم: حضور در ماه‌های خاص مختلف سال به دلیل وجود تعطیلات، ایام و شرایط خاص در تقاضای بنزین نقشی اساسی دارد که می‌توان به فروردین ماه و تعطیلات نوروزی اشاره نمود. که رشد تعطیلات بر اساس تقویم به صورت دوره ای تکرار می‌شود. و رفتار ماهانه خاصی را نشان می‌دهد.

جدول ۵ جدول آمار توصیفی داده ها

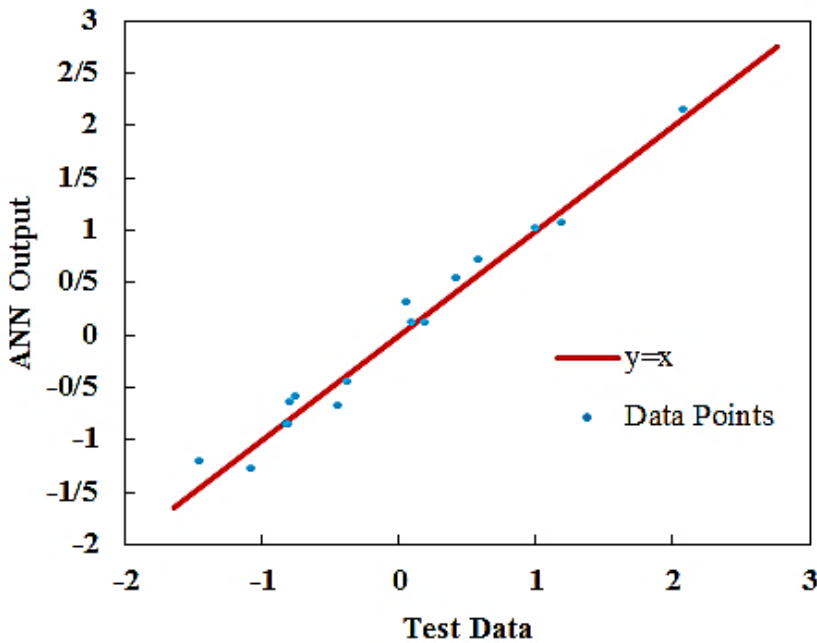
Mean	Median	Standard Deviation	Variance	Parameter
8031426	8028564	180132.6	3.24E+10	X1
2717.889	2010	1314.77	1728620	X2
93310.89	91360	27005.79	7.29E+08	X3
0.390889	0.391	0.009195	8.45E-05	X4
78.28889	70	36.89157	1360.988	X5
0.116444	0.123	0.084579	0.007154	X6
10.87544	10.836	0.52716	0.277897	X7

۵. خروجی و نتایج

خروجی مدل با توجه به داده‌های واقعی مدل خروجی مربوطه در شکل ۲ کشیده شده است. نزدیکترین نقاط نمودار به خط $x = y$ ، نشان دهنده آموزش بهتر و خطای کمتری از مدل است. داده‌های آزمایشی همراه با خروجی مربوطه شبکه عصبی در شکل ۳ نشان داده شده است. نزدیکی این نقاط گراف به خط $x = y$ نشان دهنده خطای کمتر و همگرایی بهتر شبکه‌های عصبی است.



شکل ۲ همگرایی خروجی مدل برای داده‌های آموزش



شکل ۳ همگرایی خروجی مدل برای داده‌های آزمون

با استفاده از مدل، ابتدا، از طریق انجام تحلیل حساسیت بر متغیرهای مختلف، میزان تأثیر و نحوه تغییر آنها در خروجی مدل بررسی می‌شود. سپس، با استفاده از سناریوهای مختلف، میزان تقاضای بنزین در بخش حمل و نقل تهران در سال‌های آینده پیش بینی می‌شود.

برای تعیین حساسیت خروجی نسبت به متغیرهای مختلف ورودی، تغییرات در متغیر خروجی قابل مشاهده است با تغییر ورودی مورد نظر و حفظ متغیرهای ورودی دیگر ثابت. میانگین نسبت خروجی به تغییرات هر ورودی تغییر کرده است. توجه داشته باشید که متغیر X_8 ماه سال است و در این تحلیل نیازی نیست.

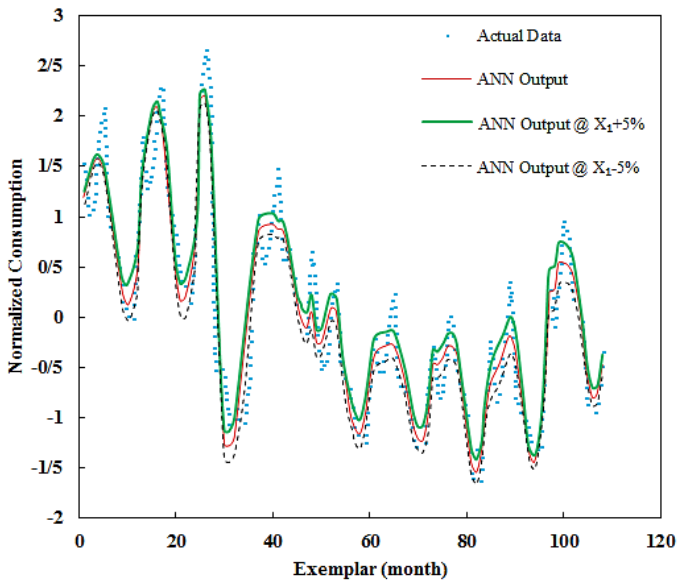
برای تعیین حساسیت خروجی به متغیرهای ورودی مختلف، با اعمال تغییرات به ورودی مورد نظر و حفظ متغیرهای ورودی دیگر، با توجه به معادله (۱)، تغییرات متغیر خروجی مشاهده شده است. تغییرات بزرگتر از متغیر خروجی در رابطه با تغییرات متغیر ورودی و سازگارتر آن در نمونه‌های مختلف است، هر چه بیشتر متغیر مورد نظر در خروجی تأثیر گذار باشد. جدول ۶ شامل نسبت تغییرات خروجی به تغییرات متغیرهای مختلف می‌شود.

$$S_{\omega}^F = \frac{\partial F/F}{\partial \omega/\omega} \quad (1)$$

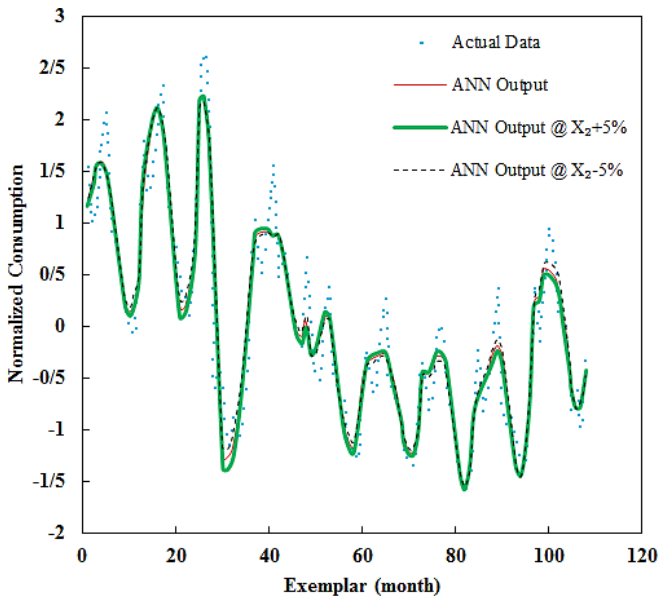
جدول ۶ نسبت تغییرات خروجی به تغییرات هر متغیر

متغیرها	نرخ تغییرات ($\overline{S_{\omega}^F}$)
X_1	1.596
X_2	-0.285
X_3	-0.622
X_4	-0.373
X_5	0.431
X_6	-2.580
X_7	0.698

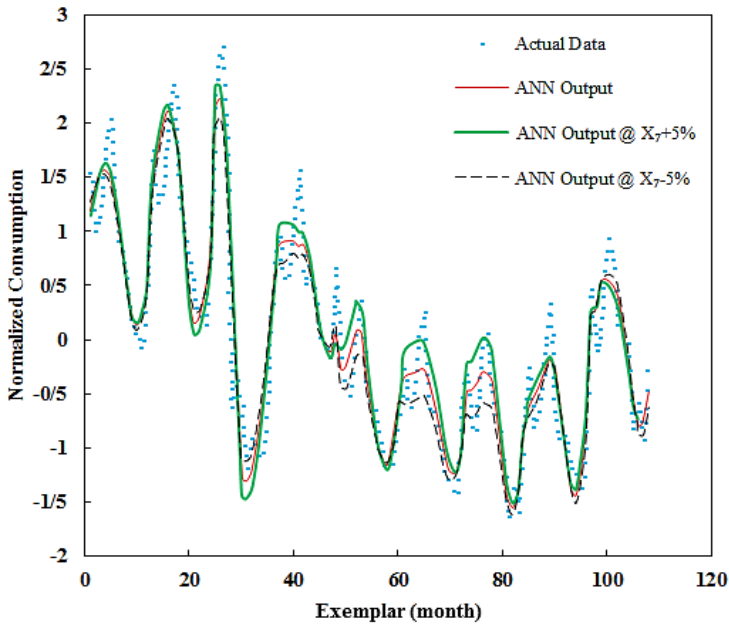
با توجه به میزان تاثیر تغییرات، متغیرهای مختلفی که موجب تفاوت در نتایج نهایی مدل می‌شوند مشاهده می‌شود. می‌توان نتیجه گرفت که خروجی مدل دارای حساسیت بالا نسبت به متغیرهای X_1 ، X_6 و X_7 است. حساسیت مدل، بر خلاف آنچه که انتظار می‌رود، در مقایسه با قیمت بنزین بسیار زیاد نیست. این موضوع که با یافته‌های قبلی Suganthi و Samuel (۲۰۱۲) و Shariatzadeh و همکاران (۲۰۱۵) مطابقت دارد، نشان دهنده تاثیر نسبتاً پایین قیمت به مصرف انرژی است، زیرا انرژی یک مزیت ضروری و ناپایدار است. تغییرات متغیر X_6 که نسبت هیبریدی به خودروهای بنزینی را نشان می‌دهد، بیشترین تاثیر را در تغییرات خروجی دارد و بعد از آن، جمعیت جمعیت مهم‌ترین نقش را ایفا می‌کند. در نهایت، متغیر سن متوسط وسایل نقلیه که به عنوان شاخص بازده مورد توجه قرار می‌گرفت، تأثیر قابل توجهی بر خروجی داشت. نتایج تجزیه و تحلیل حساسیت با تغییر اندازه جمعیت، قیمت، نسبت خودروهای ترکیبی به بنزین و طول عمر وسایل نقلیه به ترتیب در شکل ۴ تا ۷ ارائه شده است.



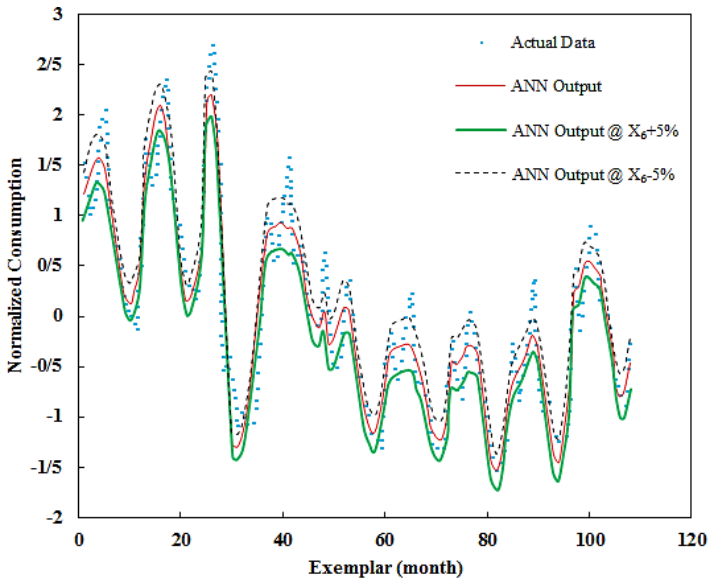
شکل ۴. نتایج تجزیه و تحلیل حساسیت در بهترین ANN برای اندازه جمعیت



شکل ۵. نتایج تجزیه و تحلیل حساسیت در بهترین ANN برای قیمت بنزین



شکل ۶. نتایج تجزیه و تحلیل حساسیت در بهترین ANN برای نسبت ماشین‌های هیبریدی به بنزینی



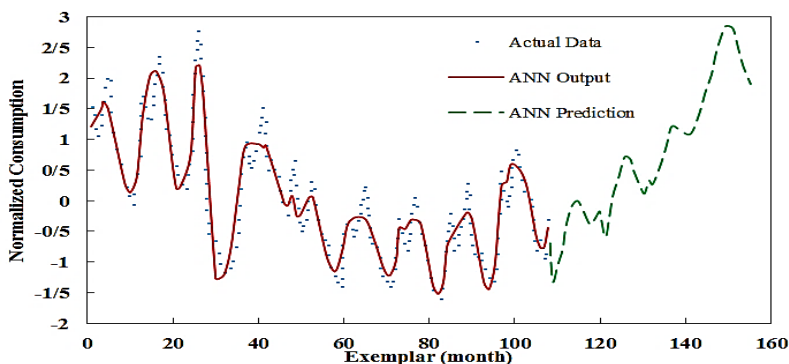
شکل ۷. نتایج تجزیه و تحلیل حساسیت در بهترین ANN برای میانگین عمر وسایل نقلیه

سپس، با توجه به تغییرات ورودی در آینده، خروجی برای سناریوهای مختلف به دست می‌آید و تقاضای بنزین برای سال‌های آینده در کلانشهر تهران پیش بینی می‌شود. برای این منظور، سه سناریو برای روند تغییرات متغیرهای ورودی در آینده در نظر گرفته شده و پیش بینی‌ها بر اساس آنها انجام می‌شود. پیش فرض سناریوی اول آن است که قیمت واقعی بنزین ثابت است، رشد جمعیت برابر با ۰.۸ درصد است، رشد متوسط درآمد خانوار شهری ۸.۱ درصد در نظر گرفته شده است، رشد قیمت کالاها و خدمات مصرفی برابر با ۸ درصد است، ضریب جینی روند تغییرات پنج سال گذشته را ادامه خواهد داد، نسبت هیبرید به اتومبیل‌های بنزین فرض ثابت است، میانگین عمر اتومبیل با روند فعلی تا ۹ سال کاهش می‌یابد و پس از آن ثابت می‌شود.

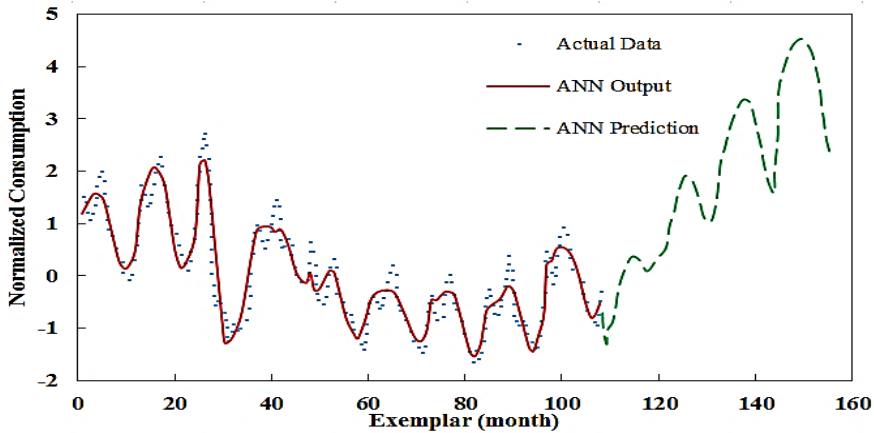
در سناریوی دوم فرض می‌شود جمعیت به مدت ۳ سال با نرخ فعلی (۰.۹٪) رشد می‌کند و سپس با رشد ۰.۶٪ ادامه می‌یابد، میانگین درآمد شهری براساس نرخ رشد فعلی خود، پیش بینی می‌شود، قیمت بنزین برای مدت ۳ سال باقی خواهد ماند، و پس از آن با میزان ۱۰ درصد افزایش می‌یابد، بقیه مفروضات مطابق سناریوی اول هستند. در این سناریو اثربخشی اقدامات اصلاحی مانند افزایش وسایل نقلیه هیبریدی، کاهش عمر طول عمر خودروها و در رابطه با تقاضای بنزین در آینده مورد بررسی قرار می‌گیرد.

پیش فرض سناریوی سوم آن است که نسبت خودروهای ترکیبی به بنزین با میزان ۲۰ درصد افزایش می‌یابد و پس از آن متوقف خواهد شد، میانگین عمر اتومبیل‌ها به طور نمادین به ۸ سال کاهش می‌یابد، قیمت بنزین با توجه به مقدار پیش بینی شده افزایش خواهد یافت، بقیه مفروضات مطابق سناریوی اول هستند.

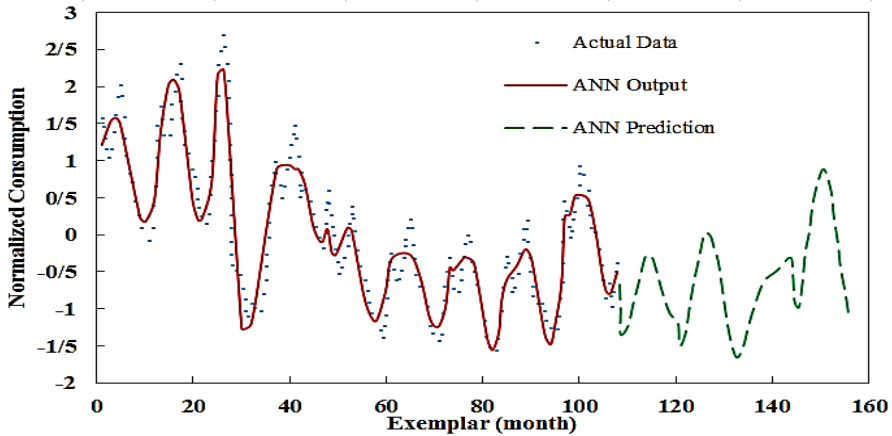
نتایج استفاده از این سه سناریو در شکل‌های ۸ تا ۱۰ نشان داده شده است.



شکل ۸. پیش بینی مصرف بنزین بر اساس مدل خروجی با فرضیه سناریوی اول



شکل ۹. پیش بینی مصرف بنزین بر اساس مدل خروجی با فرضیه سناریوی دوم



شکل ۱۰. پیش بینی مصرف بنزین بر اساس مدل خروجی با فرضیه سناریوی سوم

۶. نتیجه گیری و پیشنهادات

در این مطالعه، یک مدل برای مصرف سوخت شهری در بخش حمل و نقل شهری در کلانشهر تهران از طریق شبکه عصبی مصنوعی توسعه داده شد. متغیرهای ورودی مدل پیشنهادی، قیمت واقعی سوخت، اندازه جمعیت، درآمد خانواده متوسط شهری، ضریب جینی و شاخص قیمت کالاها و خدمات مصرفی به عنوان متغیرهای اجتماعی و اقتصادی و متوسط عمر وسایل نقلیه بود شاخص کارایی و نسبت خودروهای

هیبریدی به بنزین و ماه سال. شبکه عصبی پیشنهاد شده از نوع پراپرترون چند لایه با لایه پنهان با ۱۳ نورون است. برای آموزش شبکه استفاده از الگوریتم بازگشتی استفاده شد. داده‌ها مربوط به سال‌های ۱۳۸۸ تا ۱۳۹۶ بود و به صورت ماهانه مورد توجه قرار گرفتند. آموزش شبکه‌های عصبی با داده‌های آموزشی انجام شد و دقت پیش بینی با مقایسه خروجی شبکه با داده‌های آزمون تایید شد. تأثیر پارامترهای مختلف ساختار و آموزش شبکه عصبی بر خطای آن اندازه گیری شد و پاسخ بهینه ارائه شد. میانگین خطای $\% ۸.۸$ و $\% ۴.۶$ برای داده‌های آموزشی و آزمون به دست آمد. این مقدار خطا می‌تواند به عنوان یک معیار برای عملکرد مناسب شبکه‌های عصبی در ارائه مدل مصرف سوخت در بخش حمل و نقل شهری تهران در نظر گرفته شود.

در نهایت مدل پیشنهادی برای تحلیل حساسیت و پارامترهای مهم‌تر شناسایی شد. نتایج نشان داد که نسبت خودروهایی ترکیبی به بنزینی $S_{X6}^F = -2.580$ ، جمعیت تهران $S_{X1}^F = 1.596$ و میانگین عمر وسایل نقلیه $S_{X7}^F = 0.698$ تأثیر بیشتری بر تقاضای بنزین در بخش حمل و نقل دارند. و با در نظر گرفتن سه سناریوی متفاوت از متوسط، بدبین و خوش بینانه، مصرف سوخت برای ۴۸ ماه آینده پیش بینی شده است.

منابع

- [33] Al-Ghandoor, Ahmed, Murad Samhour, Ismael Al-Hinti, Jamal Jaber, and Mohammad Al-Rawashdeh. "Projection of future transport energy demand of Jordan using adaptive neuro-fuzzy technique." *Energy* 38, no. 1 (2012): 128-135.
- [34] Aydinalp-Koksal, Merih, and V. Ismet Ugursal. "Comparison of neural network, conditional demand analysis, and engineering approaches for modeling end-use energy consumption in the residential sector." *Applied Energy* 85, no. 4 (2008): 271-296 .
- [35] CBI Economic Time Series Database. Available online: <http://tsd.cbi.ir/DisplayEn/Content.aspx>
- [36] Ermis, K., A. Midilli, I. Dincer, and M. A. Rosen. "Artificial neural network analysis of world green energy use." *Energy Policy* 35, no. 3 (2007): 1731-1743 .
- [37] Geem, Zong Woo, and William E. Roper. "Energy demand estimation of South Korea using artificial neural network." *Energy policy* 37, no. 10 (2009): 4049-4054 .
- [38] Ghaderi, S.F., Mir Jalili, M., 2005. Analysis of Iran's gasoline demand and factors affecting it. presented at 4th International Industrial Engineering Conference. Tarbiat Modares University, Tehran, Iran. 2005. (in Persian)

- [39] Haykin, Simon S. *Neural networks and learning machines*. Vol. 3. Upper Saddle River, NJ, USA:: Pearson, 2009.
- [40] Hornik, Kurt, Maxwell Stinchcombe, and Halbert White. "Multilayer feedforward networks are universal approximators." *Neural networks* 2, no.5 (1989): 359-366..
- [41] Institute for International Energy Studies. Available online: <http://www.iies.ac.ir/en>
- [42] Jebaraj, S., and S. Iniyar. "A review of energy models." *Renewable and Sustainable Energy Reviews* 10, no. 4 (2006): 281-311 .
- [43] Kubat, Miroslav. *An introduction to machine learning*. Springer International Publishing, 2015.
- [44] Leshno, Moshe, Vladimir Ya Lin, Allan Pinkus, and Shimon Schocken. "Multilayer feedforward networks with a nonpolynomial activation function can approximate any function." *Neural networks* 6, no. 6 (1993): 861-867 .
- [45] Limanond, Thirayoot, Sajjakaj Jomnonkwao, and Artit Srikaew. "Projection of future transport energy demand of Thailand." *Energy policy* 39, no. 5 (2011): 2754-2763.
- [46] Macro Planning Office of Electricity and Energy. Available online: <http://pep.moe.gov.ir> (in Persian)
- [47] Mazrati, M. "Age estimation of car fleet and its impact on fuel consumption in iran: efficiency vis-à-vis renovation." (2007): 6-26 .
- [48] Ministry of Industry, Mine and Trade, Islamic Republic of IRAN. Available online: <http://en.mimt.gov.ir>
- [49] Moore, Christopher W., Barbara Zielinska, Gabrielle Petron, and Robert B. Jackson. "Air impacts of increased natural gas acquisition, processing, and use: a critical review." *Environmental science & technology* 48, no. 15 (2014): 8349-8359 .
- [50] Murat, Yetis Sazi, and Halim Ceylan. "Use of artificial neural networks for transport energy demand modeling." *Energy policy* 34, no. 17 (2006): 3165-3172.
- [51] Nasr, G. E., E. A. Badr, and C. Joun. "Backpropagation neural networks for modeling gasoline consumption." *Energy Conversion and Management* 44, no. 6 (2003): 893-905 .
- [52] Nowrouzi, H, Solgi, M. 2006. "The impact of different price scenarios on gasoline consumption in Iran." *Quarterly Energy Economics Review* 4, no. 11 (2006): 63-83. (in Persian)
- [53] Sadeghi, H, Zolfeghari, M, Heidarizade, M. "Estimating gasoline demand function in the transportation sector using genetic algorithm." *Quarterly Energy Economics Review* 6, no. 21 (2009): 1-27. (in Persian)

- [54] Safa, Majeed, and S. Samarasinghe. "Determination and modelling of energy consumption in wheat production using neural networks: "A case study in Canterbury province, New Zealand". Energy 36, no. 8 (2011): 5140-5147.
- [55] Shakeri, Abbas, Teymour Mohammadi, Esfandiyar Jahangard, and Mir hossein Mousavi. "Estimation of a structural model for gasoline and diesel demand in Iran's transportation sector." (2010): 1-31 .
- [56] Shariatzadeh, Farshid, Paras Mandal, and Anurag K. Srivastava. "Demand response for sustainable energy systems: A review, application and implementation strategy." Renewable and Sustainable Energy Reviews 45 (2015): 343-350.
- [57] Statal Center of Iran. Available online: <<https://www.amar.org.ir/english><
- [58] Suganthi, L., and Anand A. Samuel. "Energy models for demand forecasting—A review." Renewable and sustainable energy reviews 16, no. 2 (2012): 1223-1240