

# پیش‌بینی تقاضای انرژی بخش حمل و نقل با استفاده از شبکه‌های عصبی: مطالعه موردی در ایران

محمدباقر منهای<sup>۱</sup>، عالیه کاظمی<sup>۲\*</sup>، حامد شکوری گنجوی<sup>۳</sup>، محمدرضا مهرگان<sup>۴</sup>، محمدرضا تقی زاده<sup>۵</sup>

۱- استاد دانشکده مهندسی برق و الکترونیک، دانشگاه امیرکبیر، تهران، ایران

۲- دانشجوی دکتری مدیریت تحقیق در عملیات دانشگاه تهران، تهران، ایران

۳- استادیار گروه مهندسی صنایع دانشگاه تهران، تهران، ایران

۴- دانشیار دانشکده مدیریت، دانشگاه تهران، تهران، ایران

۵- دانشجوی دکتری مدیریت تولید و عملیات دانشگاه تهران، تهران، ایران

پذیرش: ۸۸/۳/۲۵

دریافت: ۸۶/۹/۱۸

## چکیده

در این مقاله با استفاده از شبکه‌های عصبی مصنوعی و با در نظر گرفتن شاخص‌های اقتصادی و اجتماعی، تقاضای انرژی بخش حمل و نقل کشور در سال‌های ۱۳۸۶ تا ۱۴۰۰ پیش‌بینی شده است. از شبکه‌های عصبی رو به جلو باناظر برای پیش‌بینی و از الگوریتم پس انتشار برای آموزش شبکه‌ها استفاده شده است. برای بررسی تأثیر شاخص‌های اقتصادی و اجتماعی بر تقاضای انرژی بخش حمل و نقل، داده‌های مربوط به تولید ناخالص داخلی، جمعیت و تعداد خودرو طی سال‌های ۱۳۴۷ تا ۱۳۸۵ به کار گرفته شده است. نتایج حاصل از پیش‌بینی با این روش در مقایسه با روش رگرسیون چندمتغیره، نشان‌دهنده خطای به مراتب کمتری است؛ به طوری که درصد میانگین قدرمطلق خطا از ۱۵/۵۲٪ به ۶/۰۵٪ کاهش یافت.

**کلیدواژه‌ها:** تقاضای انرژی بخش حمل و نقل، پیش‌بینی، شبکه‌های عصبی، الگوریتم پس انتشار.



## ۱- مقدمه

رشد و حتی بقای بیشتر فعالیت‌های اقتصادی کشورهای در حال توسعه به مسئله تأمین انرژی بستگی دارد. از این‌رو دولتمردان آن کشورها سعی می‌کنند با پیش‌بینی هرچه دقیق‌تر مصرف انرژی و برنامه‌ریزی صحیح در هدایت مصرف، پارامترهای عرضه و تقاضای انرژی را به نحو مطلوب کنترل کنند. تحلیل عوامل مؤثر بر شدت افزایش مصرف و چشم‌اندازی از پیش‌بینی مصرف انرژی، این امکان را برای مدیران فراهم می‌سازد تا تدابیر لازم را در جهت کنترل متغیرهای عرضه و تقاضای انرژی اتخاذ کنند.

امروزه استفاده از تکنولوژی‌های هوشمند برای حل مسائل عملی پیچیده در بخش‌های مختلف صنعتی مورد توجه بسیار قرار گرفته‌اند. این سیستم‌ها، با انجام محاسبات بر داده‌های تجربی، قوانین کلی را فرا می‌گیرند. از این‌رو به آن‌ها سیستم‌های هوشمند می‌گویند. شبکه‌های عصبی مصنوعی جز دسته‌ای از سیستم‌های هوشمند هستند که دانش نهفته در ورای داده‌ها را با پردازش داده‌های تجربی به ساختار شبکه منتقل می‌کنند. بزرگ‌ترین مزیت شبکه‌های عصبی، توانایی آن‌ها در مدل کردن روابط غیرخطی پیچیده، بدون در نظر گرفتن فرضیات قبلی است. شبکه‌های عصبی مصنوعی ویژگی‌هایی دارند که آن‌ها را در بعضی از کاربردها مانند تشخیص الگو و مدل در سیستم‌های غیرخطی و پیچیده از دیگر روش‌ها متمایز می‌نماید؛ این ویژگی‌ها عبارت‌اند از:

- قابلیت آموزش: یعنی توانایی تنظیم وزن‌های شبکه با استفاده از داده‌های آموزشی.

- قابلیت تعمیم: یعنی پس از آموزش شبکه با استفاده از داده‌های آموزشی و تنظیم وزن‌های شبکه، شبکه قادر است یک ورودی آموزش داده نشده را بپذیرد و یک خروجی مناسب ارائه نماید.

در این مقاله با استفاده از شبکه‌های عصبی مصنوعی، تقاضای انرژی بخش حمل و نقل کشور طی سال‌های ۱۳۸۶ تا ۱۴۰۰ پیش‌بینی شده است. در بخش ۲ پیشینه تحقیق مرور شده است. در بخش ۳ موضوع تحقیق عنوان شده است. پس از آشنایی اولیه با شبکه‌های عصبی و الگوریتم پس انتشار خطا در بخش ۴، تقاضای انرژی بخش حمل و نقل کشور در بخش ۵ پیش‌بینی شده است. در بخش ۶ نتایج حاصل با روش رگرسیون چندمتغیره مورد مقایسه قرار گرفته است و در بخش ۷ نتیجه‌گیری ارائه شده است.

## ۲- مروری بر پیشینه تحقیق

سیستم‌های هوشمند، به‌ویژه شبکه‌های عصبی به دلیل عملکرد موفق در زمینه تشخیص و شناسایی مدل، در بسیاری از مسائل پیش‌بینی، مورد استفاده قرار گرفته‌اند که به طور نمونه می‌توان به موارد زیر اشاره نمود:

در سال ۱۹۹۵ نیزامی و ال گارنی برای بررسی رابطه بین مصرف انرژی الکتریکی در ایالت شرقی عربستان سعودی با داده‌های آب و هوایی، تابش‌های سراسری<sup>۱</sup> و جمعیت، از یک مدل پیش‌بینی شبکه عصبی مصنوعی رو به جلو دو لایه‌ای استفاده کردند. برای ساخت این شبکه و بررسی اعتبار آن، داده‌های مربوط به ۷ سال را مورد استفاده قرار دادند و از تکنیک بازرسی بصری<sup>۲</sup> و آزمون کای-دو برای بررسی دقت مدل استفاده نمودند [۱، ص ۲۹۹].

در سال ۱۹۹۸ مهندس و همکارانش پس از مشاهده آماری سرعت ماهیانه و روزانه باد در جدّه عربستان، یک مدل شبکه عصبی را برای پیش‌بینی سرعت باد طراحی کردند و سپس عملکرد آن را با مدل اتورگرسیو مقایسه نموده‌اند. همچنین در این مطالعه، آنالیز سری‌های زمانی تصادفی به عنوان ابزار سودمندی برای توصیف مدل اتورگرسیو مورد استفاده قرار گرفت. مدل اتورگرسیون از بازه زمانی یک ماهه برای پیش‌بینی میانگین ماهیانه و از بازه زمانی یک روزه برای پیش‌بینی میانگین روزانه سرعت باد استفاده می‌نماید [۱، ص ۳۰۰].

در این سال، ال سبا و ال امین با استفاده از یک شبکه پرسپترون چندلایه و الگوریتم پس انتشار 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 [۲، صص ۱۸۹-۱۹۷].

در سال ۲۰۰۰، کالوگیرو از تکنیک شبکه‌های عصبی مصنوعی برای تخمین میزان انرژی گرمایی مصرفی در ساختمان‌ها و پیش‌بینی مصرف انرژی در یک ساختمان خورشیدی غیرفعال استفاده نمود [۱، ص ۳۰۰].

در این سال، کالوگیرو به اتفاق بوجیک براساس شبکه عصبی مصنوعی، مدلی را برای

---

1. Global radiation  
2. Visual inspection



پیش‌بینی مصرف انرژی در یک ساختمان خورشیدی غیرفعال معرفی نمودند. آن‌ها برای ساخت شبکه از الگوریتم پس انتشار استفاده کردند [۱، ص ۳۰۰].

در این سال کرمانشاهی و آیوامیا با استفاده از شبکه‌های عصبی، مصرف برق در ژاپن تا سال ۲۰۲۰ را پیش‌بینی کردند. آن‌ها از یک شبکه سه لایه و الگوریتم پس انتشار 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. [۳، صص ۷۸۹-۷۹۷]

در سال ۲۰۰۲ دورویو و همکارانش با استفاده از روش شبکه‌های عصبی مصنوعی تابش خورشیدی را تخمین زدند [۱، ص ۳۰۰].

در این سال آیدینالپ و همکارانش یک مدل مصرف انرژی براساس شبکه‌های عصبی برای بخش مسکونی کانادا توسعه دادند [۱، ص ۳۰۰].

در این سال نصر، بدر و جون نیز با استفاده از شبکه‌های عصبی و الگوریتم پس انتشار به پیش‌بینی مصرف بنزین در کشور لبنان پرداختند [۴، صص ۸۹۳-۹۰۵].

در سال ۲۰۰۳، سو و چن با جمع‌آوری داده‌های تجربی، یک مدل شبکه عصبی مصنوعی را برای پیش‌بینی زمان‌های اوج مصرف در کشور تایوان، فرمول‌بندی نمودند [۱، ص ۳۰۰].

در سال ۲۰۰۵ مورات و سیلان با استفاده از یک شبکه عصبی سه لایه و الگوریتم پس انتشار به پیش‌بینی انرژی بخش حمل و نقل کشور ترکیه پرداختند. آن‌ها ورودی‌های شبکه عصبی را تولید ناخالص داخلی، جمعیت و تعداد خودرو در هر کیلومتر در نظر گرفتند [۵، صص ۳۱۶۵-۳۱۷۲].

### ۳- موضوع تحقیق

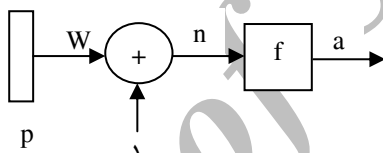
در این تحقیق با استفاده از شبکه‌های عصبی مصنوعی و با در نظر گرفتن شاخص‌های اقتصادی و اجتماعی، تقاضای انرژی بخش حمل و نقل کشور طی سال‌های ۱۳۸۵ تا ۱۴۰۰ پیش‌بینی شده است. ورودی‌های شبکه عصبی، تولید ناخالص داخلی، جمعیت و تعداد خودرو و خروجی شبکه عصبی، انرژی مصرفی در بخش حمل و نقل است. پس از آموزش شبکه، هر یک از ورودی‌های شبکه عصبی نیز با استفاده از شبکه‌های عصبی پیش‌بینی شده‌اند.

نتایج حاصل از پیش‌بینی با استفاده از شبکه‌های عصبی با روش رگرسیون چندمتغیره مورد مقایسه قرار گرفته است.

## ۴- آشنایی با شبکه‌های عصبی

### ۴-۱- ساختار شبکه عصبی

نرون کوچک‌ترین واحد پردازشگر اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. شکل (۱) ساختار یک نرون تک ورودی را نشان می‌دهد. اسکالرهایی  $p$  و  $a$  به ترتیب، ورودی و خروجی می‌باشند.



شکل ۱ ساختار نرون تک‌ورودی

میزان تأثیر  $p$  روی  $a$  به وسیله مقدار اسکالر  $w$  تعیین می‌شود. ورودی دیگر که مقدار ثابت  $b$  است در جمله بایاس  $b$  ضرب شده و سپس با  $wp$  جمع می‌شود. این حاصل جمع ورودی خالص  $n$  برای تابع محرک (یا تابع تبدیل)  $f$  خواهد بود. بدین ترتیب خروجی نرون با معادله زیر تعریف می‌شود:

$$a = f(wp + b)$$

پارامترهای  $w$  و  $b$  قابل تنظیم هستند و تابع محرک  $f$  نیز توسط طراح انتخاب می‌شود. بر اساس انتخاب  $f$  و نوع الگوریتم یادگیری، پارامترهای  $w$  و  $b$  تنظیم می‌شوند. یادگیری به این معنی است که  $w$  و  $b$  طوری تغییر می‌کنند که رابطه ورودی و خروجی نرون با هدف خاصی مطابقت نماید.

عموماً یک نرون بیش از یک ورودی دارد. معمولاً نرونی با ورودی‌های زیاد نیز به



تنهایی برای حل مسائل کفایت نمی‌کند؛ بنابراین از شبکه‌های چند لایه با  $S$  نرون در هر لایه استفاده می‌شود. در این حالت بردار ورودی  $p$  توسط نرون‌های لایه (عناصر محاسباتی) طبق رابطه  $a = f(Wp + b)$  به بردار خروجی مرتبط می‌شود [۶، ص ۴۶].

#### ۴-۱-۱- تعداد لایه‌های مخفی

تعیین تعداد لایه مخفی مسئله پیچیده‌ای است که معمولاً مستلزم تجربه و آزمون و خطاست. مطالعات نشان داده است با یک شبکه عصبی دولایه‌ای (یک لایه میانی و یک لایه خروجی) می‌توان پیش‌بینی دقیقی انجام داد [۷، صص ۱۳-۲۴].

#### ۴-۱-۲- تعداد نرون‌های لایه مخفی

تعداد نرون‌های لایه مخفی نیز معمولاً به طور تجربی و با آزمون و خطا تنظیم می‌شود. یک راه تجربی این است که تعداد نرون‌های مخفی به نسبت کوچکی از تعداد ورودی‌ها انتخاب شود. اگر شبکه عصبی به جواب مطلوب همگرا نگردد، تعداد نرون‌های لایه مخفی را افزایش می‌دهند و اگر شبکه عصبی همگرا شد و از قدرت تعمیم خوبی هم برخوردار بود، در صورت امکان تعداد نرون‌های مخفی کمتری را مورد آزمایش قرار می‌دهند. نهایتاً روی یک اندازه مناسب بر اساس عملکرد کلی سیستم توافق می‌گردد. [۶، ص ۶۰۲]

#### ۴-۲- آموزش شبکه عصبی

یکی از قابلیت‌های بسیار مهم شبکه عصبی، توانایی آموزش آن است. آموزش به این معنی است که شبکه عصبی به هنگام اعمال سیگنال ورودی و مشاهده پاسخ خود، رفتار خود را طوری تنظیم نماید که اگر در لحظه بعدی همان ورودی اعمال گردد، شبکه عصبی پاسخ مطلوب‌تری را ارائه نماید. این تنظیم رفتار توسط الگوریتم‌های بازگشتی انجام می‌گیرد که به آن‌ها الگوریتم‌های آموزش نیز می‌گویند. برای آموزش شبکه عصبی باید از ابتدا نوع آموزش در مسئله مورد بحث، مشخص شود. به طور کلی دو نوع آموزش وجود دارد: آموزش با ناظر و آموزش بدون ناظر. معمولاً برای آموزش شبکه‌های عصبی با ناظر یک تابع هزینه تعریف می‌شود و از مجموعه‌ای از داده‌های تجربی به نام داده‌های آموزشی برای تعیین وزن‌های

شبکه عصبی استفاده می‌شود. در این نوع آموزش، وزن‌های شبکه به نحوی تنظیم می‌شوند که تابع هزینه براساس داده‌های آموزشی کمینه شود [۸].

#### ۱-۲-۴- الگوریتم پس انتشار خطا

این الگوریتم در سال ۱۹۸۶ توسط دیوید راملهارت<sup>۱</sup> و جیمز مکند<sup>۲</sup> مطرح گردید [۶، ص ۳۴]. نام پس انتشار خطا با توجه به اینکه خطای محاسبه شده از لایه خروجی به لایه میانی و نهایتاً به لایه ورودی بازگشت داده می‌شود، انتخاب شده است. شاخص اجرایی این الگوریتم، میانگین مربعات خطاست که در چارچوب یادگیری با ناظر با زوج داده‌های یادگیری زیر قرار می‌گیرد:

$$\left\{ (\underline{p}^1, \underline{t}^1), (\underline{p}^2, \underline{t}^2), \dots, (\underline{p}^L, \underline{t}^L) \right\}$$

جایی که  $\underline{p}^i$  بردار ورودی شبکه و  $\underline{t}^i$  خروجی مطلوب شبکه برای ورودی  $\underline{p}^i$  است. در الگوریتم پس انتشار دو مسیر محاسباتی موجود است؛ مسیر اول پیشخور یا رفت و مسیر دوم، پسخور یا برگشت نامیده می‌شود.

۱- مسیر رفت: این مسیر با معادلات زیر بیان می‌شود:

$$\underline{a}^{(0)} = \underline{p}(k)$$

$$\underline{a}^{(l+1)}(k) = F^{(l+1)}(W^{(l+1)}(k)\underline{a}^{(l)} + b^{(l+1)}(k)), l = 0, 1, \dots, L-1$$

$$\underline{a}^{(L)}(k) = \underline{a}^{(L)}(k)$$

۲- مسیر برگشت: در این مسیر بردارهای حساسیت از لایه آخر به لایه اول برگشت داده می‌شوند. معادلات زیر دینامیک مسیر برگشت را بیان می‌کنند:

1. David Rumelhart  
2. James Mcland



$$\underline{\delta}^L(k) = -\underline{\dot{F}}^L(n) \underline{e}(k)$$

$$\underline{\delta}^L(k) = \underline{\dot{F}}^l(n^l) (W^{l+1})^T \underline{\delta}^{l+1}, l = L-1, \dots, 1$$

$$\underline{e}(k) = \underline{t}(k) - \underline{a}(k)$$

به عبارت دیگر در مسیر برگشت، شروع کار از لایه آخر، لایه خروجی است؛ جایی که بردار خطا در اختیار می‌باشد. سپس بردار خطا از سمت راست به چپ از لایه آخر به لایه اول توزیع می‌شود و گرادیان محلی، نرون به نرون با الگوریتم بازگشتی محاسبه می‌شود. در این مسیر هم پارامترهای شبکه تغییر نخواهند کرد.

۳- تنظیم پارامترها: نهایتاً ماتریس‌های وزن و بردارهای بایاس شبکه با روابط زیر تنظیم می‌شوند:

$$W^l(k+1) = W^l(k) - \alpha \underline{\delta}^l(k) (a^{l-1}(k))^T$$

$$b^l(k+1) = b^l(k) - \alpha \underline{\delta}^l(k), l = 1, 2, \dots, L$$

۴- توقف: برای توقف تکرار الگوریتم پس انتشار، از دو شاخص زیر به‌طور همزمان می‌توان استفاده نمود:

الف- میانگین مربعات خطا در هر سیکل<sup>۱</sup> (جمع مربعات خطا برای تمامی الگوهای یادگیری) کمتر از مقدار از پیش تعیین شده‌ای باشد یا اینکه فرم تغییرات در پارامترهای شبکه پس از هر سیکل خیلی کوچک باشد. باید توجه داشت که هر سیکل برابر با تعداد تکرار، به اندازه تعداد نمونه‌های یادگیری می‌باشد.

ب- نرم گرادیان خطا خیلی کوچک باشد: نرم گرادیان خطا از یک مقدار از پیش تعیین شده‌ای کوچک‌تر شود. [۶، صص ۵۴۳-۵۴۴].

### ۳-۴- اندازه و افراز داده‌ها

همانند سایر مدل‌های تجربی، شبکه‌های عصبی نیز ممکن است با تعداد داده‌های مختلف ساخته شود. داده‌های مورد استفاده برای آموزش باید به اندازه کافی زیاد باشند تا

1. Epoch



جهت‌های مختلف دامنه مسئله را پوشش دهند.

برای توسعه یک شبکه عصبی، ابتدا داده‌ها را به دو مجموعه داده‌های یادگیری و داده‌های آزمون تقسیم می‌کنیم. سپس مجدداً داده‌های یادگیری را به دو زیرمجموعه، یکی برای آموزش و دیگری برای ارزیابی عملکرد شبکه عصبی تقسیم می‌کنیم. زیرمجموعه اخیر حداکثر ۲۰٪ از کل داده‌های یادگیری را تشکیل می‌دهد [۶، ص ۶۰۱].

داده‌های آموزش برای تنظیم وزن‌ها مورد استفاده قرار می‌گیرند. داده‌های تست طی فرایند یادگیری برای کنترل پاسخ شبکه عصبی مورد استفاده قرار می‌گیرند. با توجه به عملکرد شبکه عصبی بر روی داده‌های تست ممکن است معماری شبکه عصبی تغییر کند یا تعداد سیکل‌های آموزش بیشتری مورد نیاز باشد. داده‌های اعتبار پس از انتخاب بهترین شبکه عصبی برای بررسی میزان دقت شبکه عصبی، مورد استفاده قرار می‌گیرند.

#### ۴-۴- نرمالایز کردن داده‌ها

نرمالایز کردن داده‌ها در دامنه‌ای مثل ۰ تا ۱ برای اینکه داده‌های بزرگتر ارزش بالاتری نسبت به داده‌های کوچکتر نداشته باشند و برای جلوگیری از اشباع زود هنگام نرون‌های مخفی که مانع یادگیری شبکه عصبی می‌شود، ضروری است. روش استاندارد برای نرمالایز کردن داده‌های ورودی و خروجی وجود ندارد. یک روش برای نرمالایز کردن داده‌ها در بازه  $[\lambda_1, \lambda_2]$  به صورت معادله زیر می‌باشد.

$$x_i = \lambda_1 + (\lambda_2 - \lambda_1) \left( \frac{z_i - z_i^{\min}}{z_i^{\max} - z_i^{\min}} \right)$$

$x_i$  مقدار نرمالایز شده  $z_i$ ،  $z_i^{\max}$  و  $z_i^{\min}$  مقادیر ماکزیمم و مینیمم  $z_i$  هستند [۹،

صص ۳-۳۱].

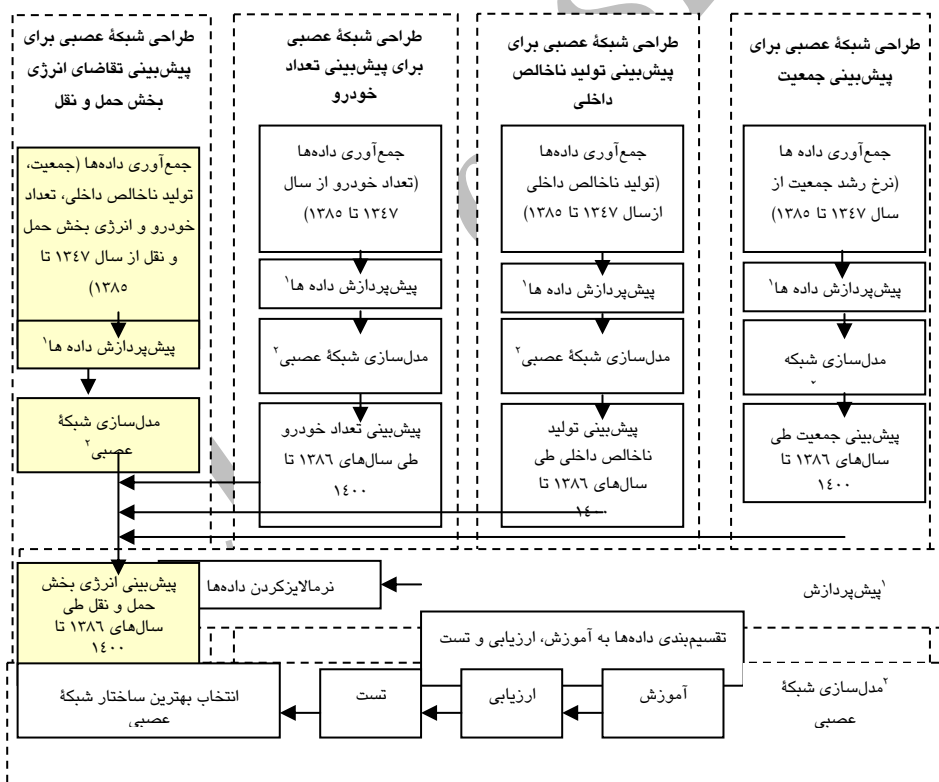
#### ۵- پیش‌بینی تقاضای انرژی بخش حمل و نقل با استفاده از شبکه‌های

##### عصبی

برای پیش‌بینی تقاضای انرژی با استفاده از روش‌های آماری مانند مدل‌های رگرسیون، اتورگرسیون و میانگین متحرک، باید از ابتدا فرم رابطه تابعی بین متغیر وابسته (مصرف انرژی)



با متغیرهای مستقل (جمعیت کل کشور، تولید ناخالص داخلی و تعداد خودرو) مشخص باشد. در اکثر مواقع و برای سادگی، روابط خطی، درجه دوم یا لگاریتمی فرض می‌شوند و این ساده‌سازی ممکن است منجر به نتایج نادرستی شود. تعیین رابطه تابعی بین مصرف انرژی و عوامل مؤثر بر آن، مسئله بسیار پیچیده‌ای است و به سادگی امکان‌پذیر نیست. استفاده از سیستم‌های هوشمند نظیر شبکه‌های عصبی که در سال‌های اخیر مورد توجه بسیاری از متخصصین امر قرار گرفته‌اند، معقول به نظر می‌رسد [۸]. در این بخش مطابق با شکل (۲) تقاضای انرژی بخش حمل و نقل کشور برای سال‌های ۱۳۸۵ تا ۱۴۰۰ پیش‌بینی شده است.



شکل ۲ روند مدل‌سازی تقاضای انرژی بخش حمل و نقل

برای پیش‌بینی مصرف انرژی در بخش حمل و نقل، یک شبکه عصبی دولایه‌ای کاملاً متصل به هم با یک لایه مخفی و یک لایه خروجی در نظر گرفته شد. ورودی‌های شبکه عصبی تولید ناخالص داخلی، جمعیت و تعداد خودرو و خروجی شبکه عصبی انرژی مصرفی در بخش حمل و نقل است، با توجه به اینکه شبکه عصبی قادر است فقط مقادیر بین صفر تا یک را پردازش کند، داده‌ها نرمالایز شدند. از تابع زیگموئید  $f(x) = \frac{1}{1+e^{-x}}$  به عنوان تابع تحریک نرون‌های لایه مخفی و از تابع همانی  $f(x) = x$  به عنوان تابع تحریک نرون لایه خروجی استفاده شده است. برای آموزش شبکه عصبی، تابع هزینه، میانگین مربعات خطای بین مقادیر واقعی و مقادیر به دست آمده از شبکه عصبی و داده‌های آموزشی است و داده‌های مربوط به سال‌های ۱۳۴۷ تا ۱۳۸۵ [۱۰؛ ۱۱] مطابق با جدول (۱) به عنوان ورودی‌ها و خروجی‌های شبکه در نظر گرفته شده‌اند. داده‌های مربوط به تولید ناخالص داخلی، جمعیت و انرژی از وزارت نیرو و داده‌های مربوط به تعداد خودرو از وزارت صنایع و معادن جمع‌آوری شده‌اند. روش استاندارد برای کمینه‌شدن تابع هزینه و در نتیجه آموزش شبکه عصبی، الگوریتم پس انتشار خطا می‌باشد.

جدول ۱ داده‌های مدل

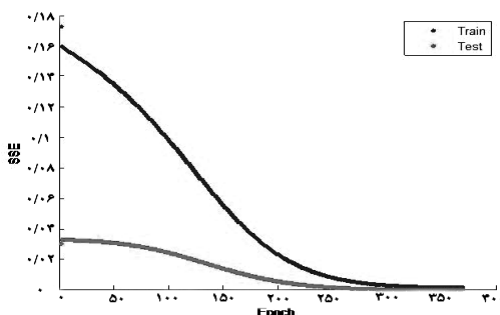
سال	GDP* (میلیارد ریال)	جمعیت* (هزار نفر)	تعداد خودرو**	مصرف نهایی انرژی در بخش حمل و نقل* (میلیون بشکه معادل نفت خام)
۱۳۴۷	۹۹۰۰۱	۲۷۲۰۸	۱۹۲۵۴	۱۵/۴
۱۳۴۸	۱۱۱۶۱۲	۲۷۹۴۶	۴۸۳۹۰	۱۷/۷
۱۳۴۹	۱۲۲۵۸۹	۲۸۷۰۵	۴۸۱۹۹	۲۰/۲
۱۳۵۰	۱۳۹۲۷۸	۲۹۴۸۴	۱۲۰۰۰۸	۲۲/۴
۱۳۵۱	۱۶۲۵۵۷	۳۰۲۸۴	۱۶۸۰۹۰	۲۸/۳
۱۳۵۲	۱۷۴۶۶۸	۳۱۱۰۶	۲۲۸۳۳۱	۳۲/۹
۱۳۵۳	۱۹۶۵۸۱	۳۱۹۵۱	۳۲۹۵۰۳	۴۰/۸
۱۳۵۴	۲۰۶۱۱۴	۳۲۸۱۸	۴۷۶۶۹۶	۴۹

ادامه جدول ۱

سال	GDP* (میلیارد ریال)	جمعیت* (هزار نفر)	تعداد خودرو**	مصرف نهایی انرژی در بخش حمل و نقل* (میلیون بشکه معادل نفت خام)
۱۳۵۵	۲۴۲۳۲۶	۳۳۷۰۹	۶۳۵۰۰۳	۵۷/۲
۱۳۵۶	۲۳۶۶۴۵	۳۵۰۲۵	۸۱۹۱۰۴	۵۷/۵
۱۳۵۷	۲۱۹۱۹۱	۳۶۳۹۳	۲۰۳۶۷۵۶	۵۸/۳
۱۳۵۸	۲۰۹۹۱۹	۳۷۸۱۴	۲۱۲۳۴۹۳	۵۴/۱
۱۳۵۹	۱۷۸۱۴۹	۳۹۴۹۱	۲۲۱۱۰۱۹	۵۳/۶
۱۳۶۰	۱۷۰۲۸۱	۴۰۸۲۶	۲۳۱۳۴۳۳	۱۵/۴
۱۳۶۱	۱۹۱۶۶۷	۴۲۴۲۰	۲۴۰۱۰۷۱	۵۸/۷
۱۳۶۲	۲۱۲۸۱۷	۴۴۰۷۷	۲۵۵۸۷۹۷	۷۲/۳
۱۳۷۰	۲۴۵۰۳۶	۵۵۸۳۷	۳۰۱۱۳۳۱	۱۰۴
۱۳۷۱	۲۵۴۸۲۳	۵۶۹۶۳	۳۱۱۵۴۰۵	۱۰۹/۵
۱۳۷۲	۲۵۸۶۰۱	۵۸۱۱۴	۳۱۷۷۸۳۶	۱۲۲/۱
۱۳۷۳	۲۵۹۸۷۶	۵۹۲۹۰	۳۲۳۹۶۹۲	۱۴۴/۶
۱۳۷۴	۲۶۷۵۳۴	۵۹۱۵۱	۳۳۲۶۴۵۱	۱۴۱/۹
۱۳۷۵	۲۸۳۸۰۷	۶۰۰۵۶	۳۴۳۸۴۱۸	۱۴۷/۹
۱۳۷۶	۲۹۱۷۶۹	۶۱۰۷۰	۳۵۹۸۸۶۰	۱۵۳/۲
۱۳۷۷	۳۰۰۱۴۰	۶۲۱۰۳	۳۷۸۹۷۵۲	۱۶۱/۲
۱۳۷۸	۳۰۴۹۴۱	۶۳۱۵۲	۴۰۱۵۸۸۸	۱۷۰/۳
۱۳۷۹	۳۲۰۰۶۹	۶۴۲۱۹	۴۲۹۸۲۴۳	۱۸۳/۴
۱۳۸۰	۳۳۰۵۶۵	۶۵۳۰۱	۴۶۶۱۶۰۵	۱۹۴/۴
۱۳۸۱	۳۵۵۵۵۴	۶۶۳۰۰	۵۱۷۵۴۰۱	۲۰۸/۹
۱۳۸۲	۳۷۹۸۳۸	۶۷۳۱۵	۵۸۹۸۶۱۷	۲۲۰/۹
۱۳۸۳	۳۹۸۲۳۴	۶۸۳۴۵	۶۷۵۹۸۳۱	۲۳۴
۱۳۸۴	۴۲۰۹۲۸	۶۹۳۹۰	۷۷۴۴۴۴۵	۲۵۴/۳
۱۳۸۵	۴۴۶۸۸۰	۷۰۴۹۶	۸۸۱۹۳۶۶	۲۷۰/۴

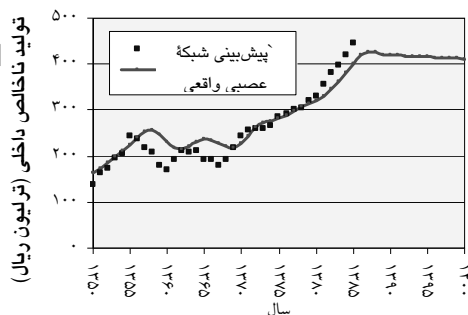
مأخذ: وزارت نیرو\* و وزارت صنایع و معادن\*\*

مدل مذکور با استفاده از نرم افزار MATLAB کدنویسی شد. شبکه عصبی در سیکل ۳۶۹ با استفاده از داده‌های آموزش و تست مطابق با شکل (۳) همگرا شد.

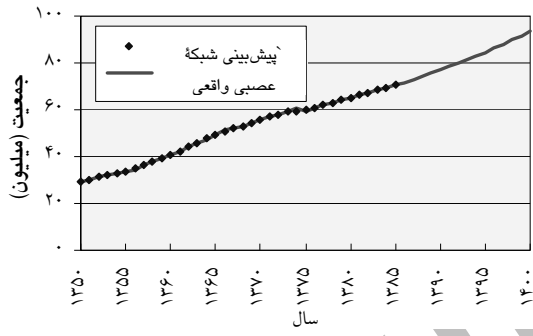


شکل ۳ همگرایی شبکه عصبی

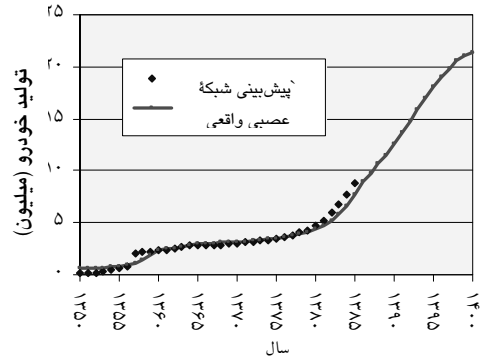
برای پیش‌بینی انرژی بخش حمل و نقل طی سال‌های آینده به داده‌های پیش‌بینی تولید ناخالص داخلی، جمعیت و تعداد خودرو طی سال‌های ۱۳۸۶ تا ۱۴۰۰ نیاز است. این داده‌ها با استفاده از شبکه‌های عصبی پیش‌بینی شدند. برای پیش‌بینی داده‌های مذکور، شبکه‌های عصبی با ۳، ۴، ۵، ۶ و ۷ ورودی مدلسازی و با الگوریتم پس انتشار خطا آموزش داده شدند. بهترین ساختارهای شبکه عصبی با توجه به مقدار خطا انتخاب شدند و بدین ترتیب مقادیر آینده تولید ناخالص داخلی، جمعیت و تعداد خودرو برای سال‌های ۱۳۸۶ تا ۱۴۰۰ مطابق با شکل‌های (۴)، (۵) و (۶) پیش‌بینی شدند.



شکل ۴ پیش‌بینی تولید ناخالص داخلی

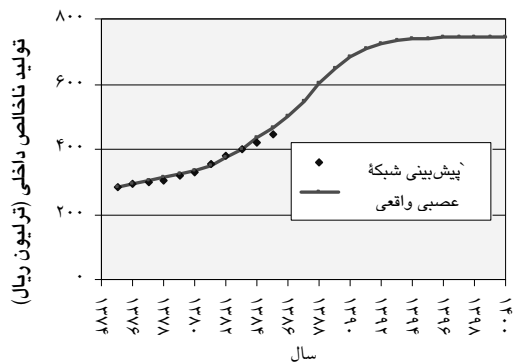


شکل ۵ پیش‌بینی جمعیت



شکل ۶ پیش‌بینی تعداد خودرو

با توجه به اینکه شبکه عصبی طراحی شده برای پیش‌بینی تولید ناخالص داخلی روندی صعودی و نزولی را آموزش می‌بیند، آینده را نیز به همین شکل تخمین می‌زند. طبق نظر خبرگان، این امر به دلیل آموزش شبکه عصبی با داده‌های مربوط به سال‌های جنگ است و بهتر است از این داده‌ها برای آموزش شبکه استفاده نشود. بنابراین شبکه عصبی با داده‌های سال‌های ۱۳۷۲ تا ۱۳۸۵ آموزش داده شد و تولید ناخالص داخلی طی سال‌های ۱۳۸۵ تا ۱۴۰۰ مطابق با شکل (۷) پیش‌بینی شد.



شکل ۷ پیش‌بینی تولید ناخالص داخلی با استفاده از داده‌های سال‌های ۱۳۷۲ تا ۱۳۸۴

بدین ترتیب، پیش‌بینی تقاضای انرژی بخش حمل و نقل کشور طی سال‌های ۱۳۸۶ تا ۱۴۰۰ مطابق با جدول (۲) می‌باشد.

جدول ۲ پیش‌بینی تقاضای انرژی بخش حمل و نقل طی سال‌های ۱۳۸۶ تا ۱۴۰۰

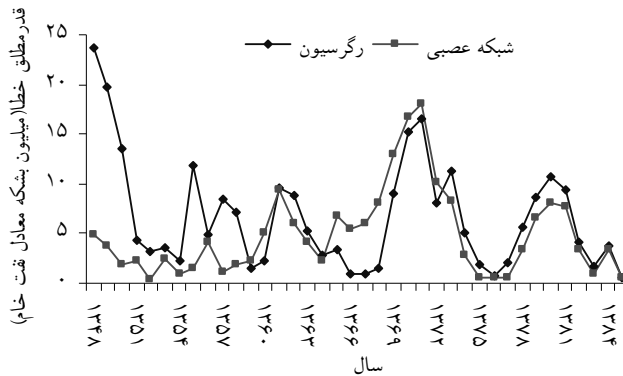
تقاضای انرژی (میلیون بشکه معادل نفت خام)	سال	تقاضای انرژی (میلیون بشکه معادل نفت خام)	سال
۴۴۱	۱۳۹۴	۲۹۲	۱۳۸۶
۴۵۰	۱۳۹۵	۳۱۷	۱۳۸۷
۴۵۹	۱۳۹۶	۳۴۲	۱۳۸۸
۴۶۷	۱۳۹۷	۳۶۶	۱۳۸۹
۴۷۳	۱۳۹۸	۳۸۶	۱۳۹۰
۴۷۹	۱۳۹۹	۴۰۳	۱۳۹۱
۴۸۵	۱۴۰۰	۴۱۷	۱۳۹۲
۴۵۰	۱۳۹۵	۴۳۰	۱۳۹۳

## ۶- مقایسه پیش‌بینی به روش رگرسیون چندمتغیره و پیش‌بینی با استفاده از شبکه‌های عصبی

با در نظر گرفتن تولید ناخالص داخلی ( $x_1$ )، جمعیت ( $x_2$ ) و تعداد خودرو ( $x_3$ ) به عنوان متغیرهای مستقل و انرژی بخش حمل و نقل ( $y$ ) به عنوان متغیر وابسته، معادله رگرسیون چندمتغیره به صورت زیر خواهد بود:

$$y = -10.6 + 0.415 x_1 + 1.83 x_2 + 7.09 x_3$$

نتایج حاصل از پیش‌بینی با استفاده از شبکه‌های عصبی در مقایسه با روش مذکور خطای به مراتب کمتری را مطابق با شکل (۸) و جدول (۳) نشان می‌دهد.



شکل ۸ مقایسه قدرمطلق خطای پیش‌بینی به روش رگرسیون چندمتغیره و شبکه‌های عصبی

جدول ۳ مقایسه خطای پیش‌بینی به روش رگرسیون چندمتغیره و شبکه‌های عصبی

نام روش	رگرسیون چندمتغیره	شبکه‌های عصبی
درصد میانگین قدرمطلق خطا <sup>۱</sup>	۱۵/۵۲٪	۶/۰۵٪
میانگین قدرمطلق خطا (میلیون بشکه معادل نفت خام)	۶/۲۳	۴/۸۳

1. average absolute error percentage (AAEP)



## ۷- نتیجه‌گیری

در این مقاله با استفاده از شبکه‌های عصبی و با در نظر گرفتن شاخص‌های اقتصادی و اجتماعی، تقاضای انرژی بخش حمل و نقل کشور پیش‌بینی شده است. ورودی‌های شبکه عصبی شامل تولید ناخالص داخلی، جمعیت و تعداد خودرو و خروجی شبکه، تقاضای انرژی بخش حمل و نقل بوده است. هر یک از ورودی‌های شبکه نیز با استفاده از شبکه‌های عصبی پیش‌بینی شده‌اند و از داده‌های سال‌های ۱۳۴۷ تا ۱۳۸۵ به منظور پیش‌بینی تقاضای انرژی بخش حمل و نقل کشور طی سال‌های ۱۳۸۶ تا ۱۴۰۰ استفاده شده است. طبق نتایج حاصل، تقاضای انرژی بخش حمل و نقل به ۴۸۵ میلیون بشکه معادل نفت خام در سال ۱۴۰۰ خواهد رسید.

نتایج حاصل از پیش‌بینی انرژی بخش حمل و نقل کشور به روش شبکه‌های عصبی با روش رگرسیون چندمتغیره مورد مقایسه قرار گرفته است. مقایسه دو روش، بیانگر این امر است که پیش‌بینی به روش شبکه‌های عصبی، دارای خطای به مراتب کمتری نسبت به روش رگرسیون است.

تحقیق حاضر، سه متغیر را به عنوان ورودی‌های شبکه عصبی در نظر گرفته است. برای تحقیقات آینده پیشنهاد می‌شود ورودی‌های دیگری مثل قیمت انرژی، میانگین مصرف انرژی خودروها و سیاست‌های آتی دولت در خصوص اصلاح مصرف انرژی در بخش حمل و نقل و سایر شاخص‌های مرتبط نیز مورد توجه قرار گیرند. همچنین تحقیقات آینده می‌تواند ترکیب شبکه‌های عصبی و الگوریتم ژنتیک را برای کاهش خطای پیش‌بینی، مورد استفاده قرار دهد.

## ۸- منابع

- [1] S. Jebaraj .S. Iniyamb ,“A review of energy models” *Renewable and Sustainable Energy Reviews* ,Vol.10 ,2006.
- [2] Tawfiq Al-Saba .Ibrahim El-Amin ,“Artificial neural networks as pplied to long-term demand forecasting” *Artificial Intelligence in Engineering* ,Vol.13 ,

1999.

[3] Bahman Kermanshahi .Hiroshi Iwamiya ، “Up to year 2020 load forecasting using neural nets” *Energy Power and Energy Systems* .vol.24 .2002.

[4] G.E. Nasr .E.A. Badr .C. Joun ، “Backpropagation neural networks for modeling gasoline consumption” *Energy Conversion and Management* .vol.44 .2003.

[5] Yetis Sazi Murat .Halim Ceylan ، “Use of artificial neural networks for transport energy demand modeling” *Energy Policy* .vol.34 .2006.

[۶] منہاج، محمد باقر؛ مبانی شبکه‌های عصبی، دانشگاه صنعتی امیرکبیر، تهران، ۱۳۸۴.

[7] Chao-Hsien Chu .Djohan Widjaja ، “Neural network system for forecasting method selection” *Decision Support Systems* .vol.12 .p.p. 13–24 .1994.

[۸] بغزیان، آلبرت؛ نصرآبادی، ابراهیم؛ پیش‌بینی مصرف فرآورده‌های نفتی: مقایسه سیستم معادلات اقتصاد سنجی و شبکه‌های عصبی، فصل نامه مطالعات اقتصاد انرژی، پاییز ۱۳۸۵.

[9] I.A. Basheer .M. Hajmeer ، “Artificial neural networks: fundamentals ، computing design and application” *Journal of Microbiological Methods* ، vol.43 .2000.

[۱۰] دفتر برنامه‌ریزی کلان برق و انرژی، ترازنامه انرژی سال ۱۳۸۴، وزارت نیرو - معاونت امور برق و انرژی، زمستان ۱۳۸۵.

[11] <http://eia.iies.org/conservation/trans2.asp>