

# پیش‌بینی مصرف فرآورده‌های نفتی: مقایسه سیستم معادلات اقتصادسنجی و شبکه‌های عصبی

آلبرت بغزیان<sup>۱</sup> - ابراهیم نصرآبادی<sup>۲</sup>

## چکیده

رشد و حتی بقای اکثر فعالیتهای اقتصادی کشورهای درحال توسعه به مساله تامین انرژی بستگی است. 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. در ایران، فرآورده‌های نفتی، بخصوص بنزین بخش عمده‌ای از حامل‌های انرژی را به‌خود اختصاص می‌دهند و مصرف روزافزون آن، بسیاری از متخصصان را بر آن داشته تا گام‌های اساسی در این زمینه بردارند. در این مقاله، با استفاده از سیستم معادلات همزمان و شبکه‌های عصبی، عوامل موثر بر مصرف فرآورده‌های نفتی، تحلیل و تقاضای فرآورده‌های نفتی طی دوره ۱۳۸۶ تا ۱۴۰۰ پیش‌بینی می‌گردد. نتایج مدلها در خصوص پیش‌بینی رشد مصرف بنزین، نفت‌گاز، نفت سفید و نفت کوره، براساس سیستم معادلات همزمان، به ترتیب، معادل ۸/۹، ۰/۹، ۰/۱ و ۰/۸ درصد و براساس مدل شبکه عصبی فازی معادل ۱۰/۱، ۱/۱، ۰/۷ و ۱/۱ درصد می‌باشند.

**واژه‌های کلیدی:** فرآورده‌های نفتی، پیش‌بینی، اقتصادسنجی، شبکه‌های عصبی.

۱. دکترای اقتصاد، albertboghosian@yahoo.com

۲. دانشجوی دکتری ریاضی کاربردی (علوم کامپیوتر) دانشگاه صنعتی امیر کبیر، nasrabadi@aut.ac.ir

## ۱. مقدمه

رشد اقتصادی و تقاضای انرژی رابطه نزدیکی با یکدیگر دارند و درک صحیح از رابطه بین آنها می‌تواند کمک شایانی به برنامه‌ریزان انرژی ارائه کند تا به نحو مطلوب متغیرهای برونزا و موثر بر تقاضای انرژی را کنترل نمایند. افزایش چشمگیر مصرف فرآورده‌های نفتی بخصوص بنزین در سالهای اخیر به یکی از مباحث مهم و روز اقتصاد کشور تبدیل شده است و یکی از دغدغه‌های اصلی دولتمردان محسوب می‌شود. با ادامه روند فعلی مصرف فرآورده‌های نفتی در کشور، پیش‌بینی می‌شود هزینه‌های سنگینی در آینده برای واردات فرآورده‌های نفتی و یارانه پرداخت شود. تحلیل عوامل موثر بر شدت افزایش مصرف و چشم‌اندازی از پیش‌بینی مصرف فرآورده‌های نفتی، این امکان را برای مدیران فراهم می‌سازد تا تدابیر لازم را در جهت کنترل متغیرهای عرضه و تقاضای انرژی اتخاذ کنند. همچنین، استفاده از تکنولوژی‌های هوشمند جهت حل مسائل عملی پیچیده در بخشهای مختلف صنعتی بسیار مورد توجه قرار گرفته‌اند. دلیل اصلی، مستدل بودن، منعطف بودن و قابلیت خود تشریحی اینگونه سیستم‌هاست. این سیستم‌ها، با انجام دادن محاسبات بر داده‌های تجربی، قوانین کلی را فرا می‌گیرند. از اینرو به آنها سیستم‌های هوشمند می‌گویند. شبکه‌های عصبی مصنوعی<sup>۱</sup> جزء دسته‌ای از سیستم‌های هوشمند هستند که دانش نهفته در ورای داده‌ها را با پردازش داده‌های تجربی به ساختار شبکه منتقل می‌کنند. شبکه‌های عصبی مصنوعی دارای ویژگی‌هایی هستند که آنها را در بعضی از کاربردها مانند تشخیص الگو و مدل در سیستم‌های غیرخطی و پیچیده از دیگر روشها متمایز می‌نماید. هدف این مقاله، بررسی روابط بین مصرف فرآورده‌های نفتی، رشد اقتصادی، رشد جمعیت و افزایش خودروها می‌باشد. در این مطالعه، علاوه بر روش کلاسیک اقتصادسنجی، از شبکه‌های عصبی مصنوعی به دلیل عملکرد موفق آنها در زمینه تشخیص و شناسایی مدل، برای پیش‌بینی تقاضای فرآورده‌های نفتی طی دوره ۱۴۰۰-۱۳۸۶ نیز استفاده می‌گردد.

## ۲. مروری بر مدل‌های پیش‌بینی تقاضای انرژی

طی سالهای گذشته مطالعاتی در زمینه مدل‌سازی و پیش‌بینی تقاضای انرژی با استفاده از روشهای اقتصادسنجی صورت گرفته است که می‌توان به تحقیقات Ediger و Akar برای

پیش‌بینی تقاضای حامل‌های انرژی طی دوره زمانی ۲۰۲۰-۲۰۰۵ در ترکیه با استفاده از روش‌های ARMA و ARIMA، تحقیقات Ghosh برای تقاضای فرآورده‌های نفتی طی دوره ۲۰۱۲-۲۰۰۱ در هند با استفاده از روش همگرایی و مدل تصحیح خطا و تحقیقات Pokharel برای پیش‌بینی مصرف حامل‌های انرژی طی دوره زمانی ۲۰۱۲-۲۰۰۵ در نپال با استفاده از سیستم معادلات همزمان اشاره نمود. در این میان، علاوه بر روش‌های کلاسیک اقتصادسنجی، سیستم‌های هوشمند و بخصوص شبکه‌های عصبی به دلیل عملکرد موفق در زمینه تشخیص و شناسایی مدل، در بسیاری از مسائل پیش‌بینی مورد استفاده قرار گرفته‌اند، که به‌طور نمونه می‌توان به موارد زیر اشاره نمود:

Al-Gami و Nizami در سال ۱۹۹۵ جهت بررسی رابطه بین مصرف انرژی الکتریکی در ایالت شرقی عربستان سعودی با داده‌های آب و هوایی، تابش‌های همه‌جانبه (Global) و جمعیت، از یک شبکه عصبی رو به جلو دو لایه‌ای<sup>۱</sup> استفاده کرده‌اند. جهت آموزش این شبکه و معتبر ساختن آن، داده‌های مربوط به ۷ سال مورد استفاده قرار گرفته‌اند.

Michalik و همکارانش برای پیش‌بینی میزان تقاضای انرژی در بخش‌های مسکونی، از متغیرهای زبانی<sup>۲</sup> و روش منطق فازی برای ایجاد یک مدل ریاضی استفاده نموده‌اند. Abdel-Aal و همکارانش، ماشین یادگیری شبکه ریاضی (Abductive) را به‌عنوان گزینه‌ای برای تحلیل مرسوم رگرسیون چند متغیره ارائه نمودند. این فناوری جهت مدل‌سازی و پیش‌بینی مصرف ماهانه انرژی الکتریکی در بخش بومی بخش‌های شرقی عربستان سعودی مورد استفاده قرار می‌گیرد.

Mohandes و همکارانش در سال ۱۹۹۸ پس از مشاهده آماری سرعت ماهیانه و روزانه باد در جده عربستان، یک مدل شبکه عصبی را جهت پیش‌بینی سرعت باد طراحی نموده و سپس عملکرد آن را با مدل اتورگرسیون مقایسه نموده‌اند. همچنین در این مطالعه، آنالیز سریهای زمانی تصادفی به عنوان ابزار سودمندی جهت توصیف مدل اتورگرسیون مورد استفاده قرار گرفت. مدل اتورگرسیون از بازه زمانی یک ماهه جهت پیش‌بینی میانگین ماهیانه و از بازه زمانی یک روزه جهت پیش‌بینی میانگین روزانه سرعت باد استفاده می‌نماید.

در سال ۱۹۹۹ روش برنامه‌ریزی خطی چند هدفه فازی جهت عمل تخصیص منابع

1. Two layered feed forward  
2. Linguistic

انرژی، توسط Chedid و همکارانش ارائه گردیده است. بدین منظور ۹ منبع انرژی و ۶ مصرف کننده نهایی در نظر گرفته شد و تحلیل حساسیت سنجی روی سیستمهای انرژی نیز صورت پذیرفت.

در سال ۲۰۰۰، Kalogirou از تکنیک شبکه عصبی مصنوعی جهت تخمین میزان انرژی گرمایی مصرفی در ساختمانها و پیشبینی مصرف انرژی در یک ساختمان خورشیدی غیرفعال (Passive) استفاده نموده است.

Kalogirou به اتفاق Bojic براساس شبکه عصبی مصنوعی مدلی را جهت پیشبینی مصرف انرژی در یک ساختمان خورشیدی غیرفعال معرفی نمودند. آنها برای آموزش شبکه از الگوریتم پس انتشار<sup>۱</sup> استفاده کردند. جهت فرمول بندی مدل برای پیشبینی میزان مصرف کوتاه مدت الکتریسیته با استفاده از تکنیک شبکه عصبی و تبدیل Wavelet صورت پذیرفت.

در سال ۲۰۰۱، Agrawal و Singh جهت تخصیص منابع انرژی برای آشپزی در خانوارهای کشور هند یک تحلیل چند هدفه را براساس منطق فازی به عمل آوردند. مهمترین هدفهای موجود در این مدل را نگرانیهای اقتصادی، زیست محیطی و فنی تشکیل می دهند.

در سال ۲۰۰۲، Che-Chiang HSU و Chian-Yon Chen با جمع آوری دادههای تجربی، یک مدل شبکه عصبی مصنوعی را جهت پیشبینی زمانهای اوج مصرف در کشور تایوان، فرمول بندی نمودند.

### ۳. سیستم معادلات همزمان

مدلهای تقاضای انرژی، چه در سطح کلان و چه در سطح خرد اقتصادی، بر مبنای تئوری مصرف کننده استوار است. مدلهای تقاضای انرژی برحسب روش شناسی برخورد با مسئله طبقه بندی شده اند. این روشها عمدتاً شامل روش آماری، اقتصادسنجی و مهندسی می باشند. نخستین تلاشها در مدلسازی تقاضای انرژی با روشهای ساده آماری شروع شد. در این راستا روشهای برون یابی شامل آنالیز تفکیکی و آنالیز تاکسونومی و سپس روشهای سری زمانی؛ اولین گامها در این رابطه بوده اند. بر اساس روش سری زمانی، نرخ رشد متوسط متغیر مورد بررسی قرار می گیرد. این مدلها کمابیش برای تصمیم گیریهای بسیار کوتاه مدت بکار برده می شوند و قادر به تبیین اثرات بلندمدت متغیرها نیستند. ضمن این که

1. Back-Propagation

رابطه علت و معلولی بین متغیرها را نیز بیان نکرده و سایر پارامترهای اقتصادی و فنی را برونزا می‌پندارند. چنانچه  $E_t$  میزان تقاضا برای انرژی در زمان  $t$  باشد، نرخ رشد حسابی آن به صورت زیر نشان داده می‌شود:

$$\alpha_t = \left( \frac{E_t - E_{t-1}}{E_{t-1}} \right) \times 100$$

چنانچه رشد تقاضا به صورت یک تصاعد هندسی تصور شود، نرخ رشد متوسط مصرف انرژی برای یک دوره  $T$  ساله (از  $t=0$  یا  $t=T$ ) برابر خواهد بود با:

$$\alpha_T = \left( \sqrt[T]{\frac{E_T}{E_0}} - 1 \right) \times 100$$

در این صورت تنها با محاسبه  $\alpha_T$  برای یک دوره زمانی و با فرض ثبات نرخ رشد تقاضا، می‌توان میزان تقاضای انرژی را برای دوره‌های  $T+1$  و بعد از آن پیش‌بینی کرد. در روش سریهای زمانی، درخصوص متغیر مورد بررسی، چنین فرض می‌شود که مقادیر گذشته آن متغیر در واقع ساختار و ماهیت رفتار متغیر را در بردارند و تمامی عوامل موثر بر آن در مقادیر گذشته آن مستتر شده‌اند. در آن صورت براساس سری زمانی گذشته آن متغیر می‌توان روند آتی متغیر را پیش‌بینی کرد.

در مدل‌های اقتصادسنجی، تابع تقاضا به صورت تقاضای مشتق شده مطرح است. سیستم معادلات تقاضا برای تمام کالاها از حل مسئله حداکثر کردن تابع مطلوبیت فردی با شرط محدودیت بودجه‌ای به دست می‌آید. سیستم مخارج خطی (LES) از حل مسئله بهینه‌سازی مصرف، هنگامی که تابع مطلوبیت صورت تعمیم یافته تابع کاب - داگلاس است، به دست آمده است. همچنین تصریح تابع مطلوبیت CES همانند تابع تولید CES در نظریه تولید و طبق شرط لازم برای حداکثر کردن مطلوبیت مشروط به محدودیت بودجه، کشش و یا درجه جایگزینی یا قابلیت جانشینی بین کالاها را به دست می‌دهد. لازم به ذکر است که جهت محاسبه سیستم توابع تقاضا، استفاده از تابع مطلوبیت مستقیم و تابع هزینه متناظر آن نیز امری رایج است. بنابراین کل پارامترهای سیستم معادلات تقاضا با استفاده از تخمین پارامترهای معادله بالا به روش حداقل مربعات معمولی قابل محاسبه است. در این مقاله، مصرف بنزین به عنوان تابعی از تولید ناخالص داخلی واقعی سرانه، قیمت واقعی بنزین، تعداد ماشین‌های بنزین سوز، تعداد موتورسیکلت‌ها و متوسط عمر ماشین‌های بنزین سوز، مصرف نفت گاز بعنوان تابعی از تولید ناخالص داخلی، جمعیت کل کشور، ارزش افزوده بخش حمل و نقل، قیمت واقعی نفت گاز، تعداد ماشین‌های

گازوئیل سوز و متغیر روند زمانی، مصرف نفت سفید به عنوان تابعی از تابعی از جمعیت کل کشور، قیمت واقعی نفت سفید و مصرف دوره قبل، و مصرف نفت کوره به عنوان تابعی از میزان مصرف دوره قبل برآورد گردیده است که معادلات مصرف به دست آمده به شرح زیر قابل بررسی است:

#### معادله مصرف بنزین

$$CGASOL = \text{Exp}(-3.352 + 0.581 * \text{LOG}(\text{GDP}/\text{POP}) - 0.167 * \text{LOG}(\text{PGASOL}/\text{CPI}) + 0.776 * \text{LOG}(\text{GASCAR} + \text{MOTORS}) + 0.145 * \text{LOG}(\text{AVGAGE}))$$

#### معادله مصرف نفت گاز

$$COGAS = -50407.003 + 1.584 * \text{POP} + 0.02 * \text{GDP} + 0.173 * \text{VATRA} - 217.041 * (\text{PGASOL}/\text{CPI}) + 0.01 * \text{OILCAR} - 1731.34 * \text{T}$$

#### معادله مصرف نفت سفید

$$CKERS = \text{Exp}(7.80 + 0.227 * \text{LOG}(\text{VAAGR}) + 0.07 * \text{LOG}(\text{PKERS}/\text{CPI}) + 0.58 * \text{LOG}(\text{CKERS}(-1)))$$

#### معادله مصرف نفت کوره

$$CKORR = \text{Exp}(0.902 + 0.90 * \text{LOG}(\text{CKORR}(-1)))$$

که در آن، CGASOL، COGAS، CKERS، CKORR به ترتیب، مصرف سالانه بنزین، نفت گاز، نفت سفید و نفت کوره (به میلیون لیتر)، GDP تولید ناخالص داخلی واقعی سرانه (هزار ریال برای هر نفر)، POP، جمعیت کل کشور، PGASOL، POGAS و PKERS به ترتیب قیمت اسمی بنزین، نفت گاز و نفت سفید و CPI، شاخص قیمتها، GASCAR، تعداد ماشینهای بنزین سوز، MOTORS، تعداد موتورسیکلتها، AVGAGE، متوسط عمر ماشینهای بنزین سوز، VATRA، ارزش افزوده بخش حمل و نقل، OILCAR تعداد ماشینهای گازوئیل سوز و T، متغیر زمان است. کلیه متغیرها بصورت لگاریتم در معادلات ظاهر شده اند. روش برآورد، برآورد سیستم معادلات به ظاهر نامرتب (SURE) می باشد.

#### ۴. شبکه‌های عصبی

شبکه‌های عصبی مصنوعی (Artificial Neural Networks) جزء دسته‌ای از سیستم‌های هوشمند هستند که دانش نهفته در ورای داده‌ها را با پردازش داده‌های تجربی به ساختار


شبکه منتقل می‌کنند. شبکه‌های عصبی مصنوعی دارای ویژگی‌هایی هستند که آنها را در برخی از کاربردها مانند تشخیص الگو و مدل در سیستم‌های غیرخطی و پیچیده از دیگر روشها متمایز می‌نماید. این ویژگی‌ها عبارتند از:

۱. قابلیت آموزش: یعنی توانایی تنظیم وزن‌های شبکه با استفاده از داده‌های آموزشی؛
۲. 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.

#### ۴-۱. ساختار شبکه عصبی

نرون کوچکترین واحد پردازش اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. شکل ۱ ساختار یک نرون با  $n$  ورودی و یک خروجی را نشان می‌دهد.

شکل ۱. ساختار یک نرون با چند ورودی



بردار  $x = (x_1, x_2, \dots, x_n)$  سیگنال‌های ورودی و اسکالر  $y$  سیگنال خروجی نرون می‌باشند. میزان تاثیر  $x$  روی  $y$  با بردار وزنی  $w = (w_1, w_2, \dots, w_n)$  مشخص می‌شود. در بسیاری از مواقع، در نظر گرفتن یک سیگنال ورودی دیگر با مقدار ثابت یک مفید خواهد بود که میزان تاثیر آن روی سیگنال خروجی با وزن  $b$  تعیین می‌شود. ورودی خالص به نرون که با  $net$  نمایش داده می‌شود با معادله زیر تعریف می‌شود:

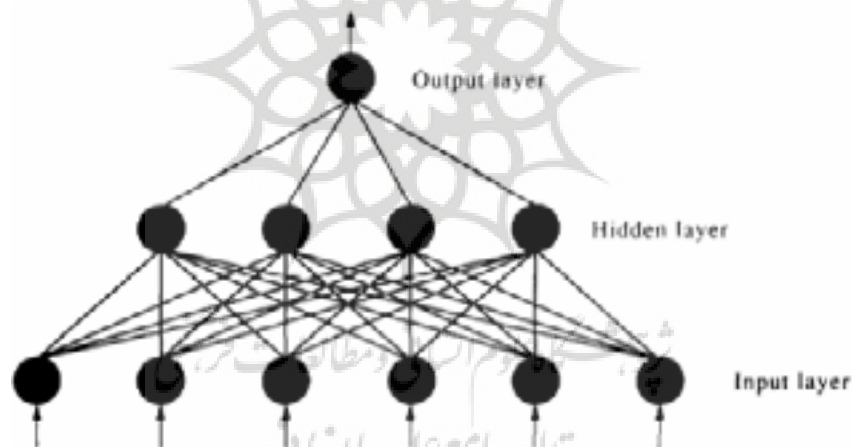
$$net := \sum_{i=1}^n w_i x_i + b$$

در این معادله، جمله  $b$  جمله اریب (بایاس) نامیده می‌شود. پس از ورود سیگنال

net به نرون، تابع تحریک یا تابع تبدیل  $f$  عمل می‌کند و سیگنال خروجی  $y$  با معادله  $y = f(\text{net})$  به دست می‌آید. وزن‌های  $w$  و  $b$  قابل تنظیم هستند و تابع تحریک  $b$  توسط تجربه مشخص می‌شود. بر اساس انتخاب  $f$  و نوع الگوریتم آموزش، وزن‌های  $w$  و  $b$  تنظیم می‌شوند. آموزش به این معنی است که  $w$  و  $b$  طوری تنظیم شوند که بتوانند رابطه بین سیگنال‌های ورودی و خروجی را بطور مناسبی توضیح دهند.

باید توجه داشت که برای حل بسیاری از مسائل، یک نرون با ورودی‌های زیاد کفایت نمی‌کند. به عنوان مثال، برای مدل‌سازی نگرشهایی با دو خروجی، احتیاج به دو نرون داریم که به طور موازی عمل کنند. در این حالت، یک لایه خواهیم داشت که از اجتماع چند نرون به دست می‌آید. شکل ۲، ساختار یک شبکه عصبی را نشان می‌دهد که از اجتماع سه لایه (لایه ورودی، لایه مخفی و لایه خروجی) به دست می‌آید.

شکل ۲. ساختار یک شبکه عصبی سه لایه ای



#### ۲-۴. 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 مساله 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 استفاده می‌شود. در این نوع آموزش، وزن‌های شبکه بنحوی تنظیم می‌شوند که تابع هزینه بر اساس داده‌های آموزشی کمینه شود.

### ۵. برآورد مدل مصرف فرآورده‌های نفتی با استفاده از شبکه‌های عصبی

برای پیش‌بینی تقاضای فرآورده‌های نفتی با استفاده از روش‌های آماری مانند مدل‌های رگرسیون، اتورگرسیو و میانگین متحرک، باید از ابتدا فرم رابطه تابعی بین متغیر وابسته (مصرف فرآورده) با متغیرهای مستقل (جمعیت کل کشور، جمعیت شهری، جمعیت روستایی، تولید ناخالص ملی، ارزش افزوده بخش صنایع و معادن، بخش حمل و نقل جاده‌ای و ریلی، بخش کشاورزی، قیمت فرآورده، تعداد خودرو بنزین‌سوز و گازوئیل‌سوز، تعداد موتورسیکلت و ظرفیت نیروگاهها) مشخص باشد. در اکثر مواقع، و برای سادگی، روابط خطی، درجه دوم و یا لگاریتمی فرض می‌شوند، هرچند این ساده‌سازی ممکن است منجر به نتایج نادرستی شود. تعیین رابطه تابعی بین مصرف فرآورده و عوامل موثر بر آن مساله بسیار پیچیده‌ای است و به سادگی امکان‌پذیر نیست. بنابراین استفاده از سیستم‌های هوشمند نظیر شبکه‌های عصبی که در سالهای اخیر مورد توجه بسیاری از متخصصین امر قرار گرفته‌اند، معقول به نظر می‌رسد.

برای پیش‌بینی مصرف هر یک از فرآورده‌های نفتی (بنزین، نفت گاز، نفت سفید و نفت کوره) یک شبکه عصبی سه لایه‌ای کاملاً متصل به هم (یک لایه ورودی، یک لایه مخفی و یک لایه خروجی) با ده نرون در لایه مخفی و یک نرون در لایه خروجی متناظر با متغیر وابسته میزان تقاضا در نظر گرفته می‌شود و از تابع همانی  $f(x) = x$  به عنوان تابع تحریک نرون‌های لایه ورودی و تابع زیگموئید  $f(x) = \frac{1}{1 + e^{-x}}$  به عنوان تابع تحریک نرون‌های لایه مخفی و خروجی استفاده می‌شود. تعداد نرون‌های لایه ورودی برای هر فرآورده با توجه به عوامل موثر بر آن متفاوت است. با توجه به اینکه شبکه قادر است فقط مقادیر بین صفر تا یک را پردازش کند، داده‌های نرمالایز می‌شوند.

برای آموزش شبکه عصبی، تابع هزینه میانگین مربعات خطای بین مقادیر واقعی و مقادیر به دست آمده از شبکه عصبی و داده‌های آموزشی و اطلاعات موجود سالهای ۱۳۶۶ تا ۱۳۸۴ در نظر گرفته شده‌اند. روش استاندارد برای کمینه شدن تابع هزینه و در نتیجه

آموزش شبکه عصبی، الگوریتم پس انتشار (Backpropagation) می باشد.

### ۶. پیش بینی مصرف فرآورده های نفتی

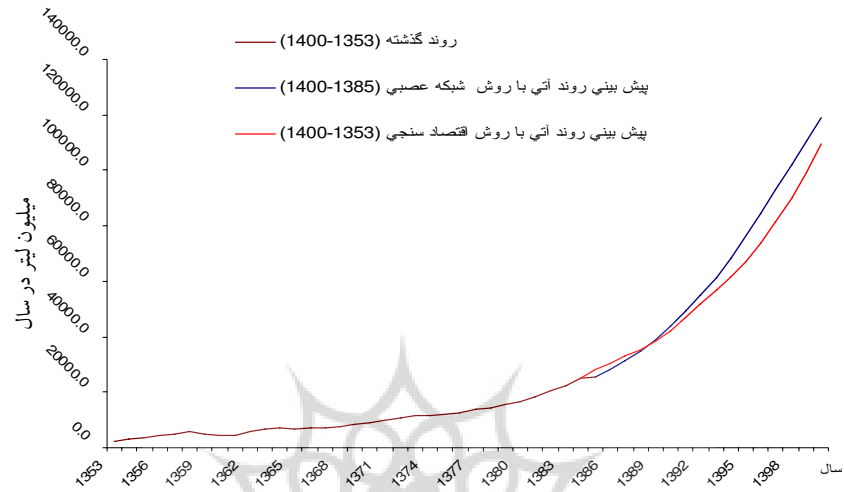
نمودارهای ۱ الی ۴ بکارگیری الگوریتم پس انتشار و نتایج حاصل از شبیه سازی معادلات مصرف نتایج برآورد را نشان می دهند. پیش بینی میزان مصرف فرآورده های نفتی ایران برای دوره ۱۴۰۰-۱۳۸۵، طبق سناریوی مشخصی برای متغیرهای مستقل در مدل، انجام می پذیرد. سناریوی استفاده شده برای پیش بینی میزان مصرف بنزین در جدول ۱ آمده است.

جدول ۱: سناریوی پیش بینی مصرف فرآورده های نفتی (سیستم معادلات اقتصادسنجی)


نام متغیر	رشد طی دوره برآورد معادلات (۱۳۸۲-۱۳۵۳)	پیش بینی نرخ رشد طبق برنامه چهارم توسعه کشور (۱۳۸۸-۱۳۸۴)	پیش بینی نرخ رشد طبق چشم انداز بیست ساله کشور (۱۴۰۰-۱۳۸۹)
متغیرهای کلان کشور			
تولید ناخالص داخلی (واقعی)	۳/۳ درصد	۸ درصد	۸/۶ درصد
ارزش افزوده بخش کشاورزی	۶/۶ درصد	۶/۵ درصد	۵/۶ درصد
ارزش افزوده بخش صنعت و معدن	۷/۴ درصد	۱۱/۲ درصد	۱۰/۵ درصد
ارزش افزوده بخش حمل و نقل جاده ای و ریلی	۶/۹ درصد	۱۱ درصد	۱۱ درصد
جمعیت کل کشور	۳/۷ درصد	۱/۴ درصد	۱/۳ درصد
تعداد ماشینهای بنزین سوز	۱۴/۵ درصد	۷ درصد	۷ درصد
متوسط عمر ماشین های بنزین سوز	-۰,۶ درصد	-۰,۶ درصد	-۰,۶ درصد
متوسط مصرف ماشین های بنزین سوز	۲ درصد	۱ درصد	۰ درصد
تعداد ماشینهای گازوئیل سوز	۸/۳ درصد	۸ درصد	۸ درصد
تعداد موتورسیکلت ها	۱۵ درصد	۱۵ درصد	۱۵ درصد
بلوک قیمتها			
قیمت (اسمی) بتزین	۱۱/۵ درصد	۱۰ درصد	۱۰ درصد
قیمت (اسمی) نفت سفید	۳/۷ درصد	۱۰ درصد	۱۰ درصد
قیمت (اسمی) نفت گاز	۸/۴ درصد	۱۰ درصد	۱۰ درصد
قیمت (اسمی) نفت کوره	۵/۹ درصد	۱۰ درصد	۱۰ درصد

نتایج پیش بینی در نمودارهای ۱ و ۲ و جدول شماره ۲ ارائه شده اند. طبق این جدول، رشد مصرف بنزین، نفت گاز، نفت سفید و نفت کوره طی دوره پیش بینی براساس سیستم معادلات همزمان، به ترتیب، معادل ۹/۵، ۹، ۱ و ۸ درصد و بر اساس مدل شبکه عصبی فازی معادل ۸/۴، ۱۱، ۷، ۱۱ درصد خواهد بود.

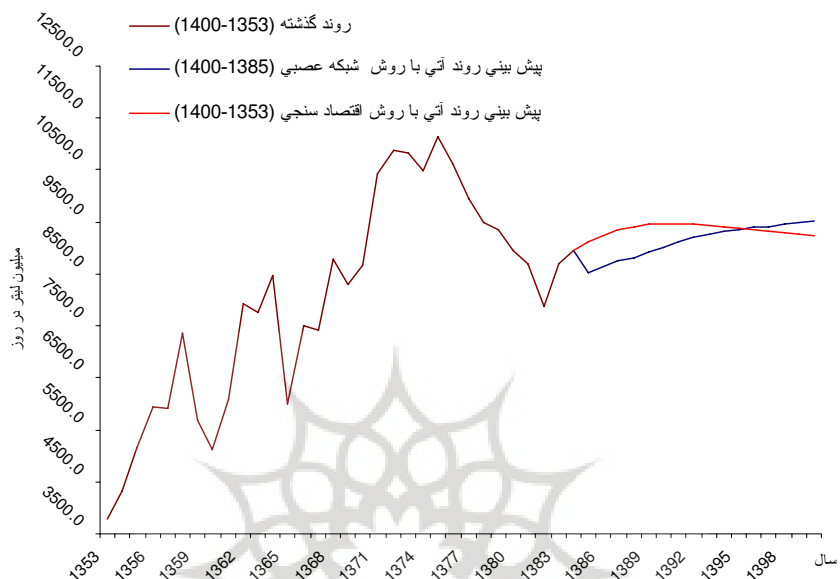
نمودار ۱. پیش‌بینی مصرف سالانه بنزین برای دوره ۱۳۸۵-۱۴۰۰




نمودار ۲. پیش‌بینی مصرف سالانه نفت گاز برای دوره ۱۳۸۵-۱۴۰۰



نمودار ۳. پیش‌بینی مصرف سالانه نفت سفید برای دوره ۱۴۰۰-۱۳۸۵



نمودار ۴. پیش‌بینی مصرف سالانه نفت کوره برای دوره ۱۴۰۰-۱۳۸۵



## فصلنامه مطالعات اقتصاد انرژی

جدول ۲. میزان پیش‌بینی مصرف حامل‌های انرژی برای دوره (۱۴۰۰-۱۳۸۵)

سال	بنزین		نفت گاز		نفت سفید		نفت کوره	
	روش اول <sup>۱</sup>	روش دوم <sup>۲</sup>	روش اول	روش دوم	روش اول	روش دوم	روش اول	روش دوم
۱۳۸۵	۲۷۹۹۲/۹	۲۵۳۹۰/۰	۲۷۵۳۴/۹	۲۷۰۹۴/۸	۹۱۱۷/۵	۸۵۲۵/۶	۱۴۴۵۱/۶	۱۴۱۵۸/۷
۱۳۸۶	۳۰۵۸۰/۰	۲۸۱۹۰/۰	۲۷۹۱۸/۷	۲۷۴۷۴/۹	۹۲۴۷/۴	۸۶۲۵/۴	۱۴۶۸۴/۲	۱۴۲۴۷/۰
۱۳۸۷	۳۲۹۲۴/۰	۳۱۳۷۰/۰	۲۸۲۸۷/۶	۲۷۸۴۸/۴	۹۳۴۴/۰	۸۷۵۸/۹	۱۴۸۹۸/۴	۱۴۵۳۲/۳
۱۳۸۸	۳۵۳۸۴/۰	۳۴۹۹۰/۰	۲۸۶۴۲/۱	۲۸۲۱۵/۵	۹۴۱۷/۲	۸۸۰۳/۲	۱۵۰۹۵/۵	۱۴۷۱۵/۸
۱۳۸۹	۳۸۴۱۷/۶	۳۹۱۰۰/۰	۲۸۹۸۲/۸	۲۸۵۷۶/۴	۹۴۵۷/۰	۸۹۲۵/۹	۱۵۲۷۶/۶	۱۴۹۹۸/۴
۱۳۹۰	۴۲۲۶۰/۲	۴۳۷۵۰/۰	۲۹۳۱۰/۱	۲۸۹۳۱/۲	۹۴۷۳/۳	۹۰۱۵/۳	۱۵۴۴۲/۹	۱۵۱۸۰/۹
۱۳۹۱	۴۶۷۹۴/۲	۴۸۹۹۰/۰	۲۹۶۲۴/۷	۲۹۲۸۰/۰	۹۴۷۳/۳	۹۱۲۵/۰	۱۵۵۹۵/۳	۱۵۳۶۳/۹
۱۳۹۲	۵۱۶۶۹/۳	۵۴۸۷۰/۰	۲۹۹۲۷/۱	۲۹۶۲۲/۹	۹۴۶۲/۱	۹۱۹۸/۶	۱۵۷۳۴/۹	۱۵۵۴۸/۰
۱۳۹۳	۵۶۶۰۶/۸	۶۱۳۹۰/۰	۳۰۲۱۷/۶	۲۹۹۶۰/۰	۹۴۴۳/۱	۹۲۷۵/۰	۱۵۸۶۲/۷	۱۵۷۳۳/۶
۱۳۹۴	۶۱۶۶۰/۲	۶۸۵۴۰/۰	۳۰۴۹۶/۸	۳۰۲۹۱/۲	۹۴۱۸/۸	۹۳۱۵/۵	۱۵۹۷۹/۶	۱۵۹۲۱/۰
۱۳۹۵	۶۷۲۰۳/۹	۷۶۲۸۰/۰	۳۰۷۶۵/۱	۳۰۶۱۶/۶	۹۳۹۰/۸	۹۳۵۹/۳	۱۶۰۸۶/۴	۱۶۱۵۰/۶
۱۳۹۶	۷۳۶۷۶/۵	۸۴۵۱۰/۰	۳۱۰۲۳/۰	۳۰۹۳۶/۳	۹۳۶۰/۴	۹۳۹۶/۹	۱۶۱۸۳/۹	۱۶۱۰۲/۶
۱۳۹۷	۸۱۳۰۱/۹	۹۳۰۸۰/۰	۳۱۲۷۰/۸	۳۱۲۵۰/۱	۹۳۲۸/۳	۹۴۰۱/۴	۱۶۲۷۲/۹	۱۶۳۹۷/۰
۱۳۹۸	۸۹۹۹۰/۱	۱۰۱۸۱۰/۰	۳۱۵۵۸/۹	۳۱۵۵۸/۱	۹۲۵۵/۱	۹۴۵۸/۹	۱۶۳۵۴/۱	۱۶۴۹۴/۲
۱۳۹۹	۹۹۴۷۶/۹	۱۱۰۴۷۰/۰	۳۱۷۳۷/۷	۳۱۸۶۰/۳	۹۲۶۱/۲	۹۴۹۷/۱	۱۶۴۲۸/۱	۱۶۶۹۴/۱
۱۴۰۰	۱۰۹۶۰۸/۵	۱۱۸۸۴۰/۰	۳۱۹۵۷/۶	۳۲۱۵۶/۷	۹۲۲۶/۸	۹۵۲۶/۳	۱۶۴۹۵/۶	۱۶۷۹۶/۹
متوسط رشد	۸/۹	۱۰/۱	۰/۹	۱/۱	۰/۱	۰/۷	۰/۸	۱/۱

### ۵. نتیجه‌گیری

رشد و حتی بقای اکثر فعالیتهای اقتصادی کشورهای در حال توسعه به مساله تامین انرژی بستگی دارد. از این رو 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. در این مقاله، با استفاده از سیستم معادلات همزمان و شبکه‌های عصبی، عوامل موثر بر مصرف فرآورده‌های نفتی، تحلیل و تقاضای فرآورده‌های نفتی طی دوره ۱۳۸۶ تا ۱۴۰۰ پیش‌بینی گردید. نتایج پیش‌بینی در خصوص رشد مصرف بنزین، نفت گاز، نفت سفید و نفت کوره طی دوره پیش‌بینی و براساس سیستم معادلات همزمان، به ترتیب، معادل ۸/۹، ۰/۹، ۰/۱ و ۰/۸ درصد و بر اساس مدل شبکه عصبی فازی معادل ۱۰/۱، ۱/۱، ۰/۷ و ۱/۱ درصد خواهد بود.

۱. سیستم معادلات همزمان

۲. شبکه عصبی

## منابع و ماخذ

۱. بانک مرکزی، حسابهای ملی، بانک مرکزی جمهوری اسلامی ایران، شماره‌های مختلف.
۲. شرکت ملی پالایش و پخش فرآورده های نفتی، گزارش‌های سالانه و ماهانه شرکت ملی پالایش و پخش فرآورده های نفتی، سالهای مختلف.
۳. عرب مازار یزدی، علی، تخمین توابع تقاضا برای فرآورده های اصلی نفت در ایران، پایان نامه کارشناسی ارشد، دانشکده اقتصاد دانشگاه علامه طباطبائی.
۴. فخرایی، سیدحمید، گزارش نهایی طرح تقاضای انرژی، پیش‌بینی تقاضای انواع انرژی (برق، گاز طبیعی و فرآورده‌های نفتی) در بخشهای مختلف مصرف‌کننده، موسسه عالی پژوهش و برنامه‌ریزی و توسعه.
۵. مزرعتی، محمد، بررسی تقاضای عمده‌ترین حاملهای انرژی در ایران، پایان‌نامه فوق لیسانس دانشکده، اقتصاد دانشگاه تهران.
۶. آقایی‌تبریزی، محمد، بنزین، چالشها و راه حلها، موسسه مطالعات بین‌المللی انرژی، ۱۳۸۵.
7. T. Al-Saba, I. El-Amin, Artificial neural networks as applied to long-term demand forecasting, *Artificial Intelligence in Engineering* 13 (1999) 189–197.
8. F. Aminzadeh, J. Barhen, N.B. Toomarian, (1999), Estimation of reservoir parameter using a hybrid neural network. *Journal of Petroleum Science and Engineering* 24 (1), 49–56.
9. E. Arsenault, J.T. Bernard, C.W. Carr and E. Genest-Laplante, A total energy demand model of Qu6bec, *EnerD, Economics*, Vol. 17, No. 2, pp. 163-171, 1995.
10. R.O. Baker, N.K. Spenceley, B. Guo, D.S. Schechter, (1998), Using an analytical decline model to characterize naturally fractured reservoirs. *SPE/DOE Improve Oil Recovery Symposium*, Tuls Oklahoma, 19–22 April 1998 (SPE 39623).
11. M. Beccali, M. Cellura, V.L. Brano, A. Marvuglia, Forecasting daily urban electric load profiles using artificial neural networks, *Energy Conversion and Management* 45 (2004) 2879–2900.
12. V.S. Ediger, S. Akar, , “ARIMA forecasting of primary energy demand by fuel in Turkey”, *Energy Policy* (2006) (article in press).
13. A.H. El-Banbi, R.A. Wattenbarger, 1996. Analysis of commingled tight gas reservoirs. *SPE Annual Technical Conference and Exhibition*, Denver, Colorado, USA, 6–9 October 1996 (SPE 36736).

14. M.J. Fetkovich, (1980), Decline curve analysis using type curves. *Journal of Petroleum Technology* June, 1065–1077.
15. A.C. Fisher, S. Devarajan, (1982)”, Exploration and Scarcity”, *Journal of Political Economy*, Vol. 90, No. 61, PP.1279-1290.
16. S. Ghosh, “Future demand of petroleum products in India”, *Energy Policy* 34 (2006) 2032–2037.
17. R.B. Gharbi, A.M. Elsharkawy, M. Karkoub, (1999). Universal neural-network-based model for estimating the PVT properties of crude oil systems. *Energy & Fuels* 13, 454–458.
18. J.M. Henderson, R.E. Quant, *Microeconomics Theory, A Mathematical Approach*, 3rd ed. 1980, Mc Graw Hill, Inc.
19. B. F. Hobbs, U. Helman, S. Jitprapaikularn, S. Konda, D. Maratukulam, Artificial neural networks for short-term energy forecasting: Accuracy and economic value, *Neurocomputing* 23 (1998) 71-84.
20. M. Hoel, (1980)”, Resource Extraction When a Future Substitute has an Uncertain Cost”, *Review of Economic Studies*, PP. 637-644.
21. Z. Huang, M.A. William (1997). Determination of porosity and permeability in reservoir intervals by artificial neural network modeling, offshore eastern Canada. *Petroleum Geoscience* 3 (3), 245–258.
22. J. C. Fuhrer, G. D. Rudebusch , “Estimating the Euler Equation For Output,” September 2002.
23. E.G. John, (1998), Simplified curve fitting using spreadsheet add-ins. *International Journal of Engineering Education* 14 (5), 375–380.
24. C.M. Kaun, H. White, Artificial neural networks: an econometric perspective, *Econometric Reviews*, 13 (1994)139-143.
25. R. K. Kaufman, C. J. Cleveland, (2001)”, Oil Production in the Lower States: Economic, Geological, and Institutional Determinates”, *The Energy Journal*, Vol. 22, no. 1, PP. 27-49.
26. N. Krichene, (2002). “ World Crude Oil and Natural gas : a demand and Supply model”, *Energy Economic* 24, PP. 557-576.
27. P. R. G. Layard, Walters, A.A, *Microeconomic theory*, 1978, Mc Graw Hill, Inc.
28. K. Li, R.N. Horne (2003), A decline curve analysis model based on Fluid flow mechanisms, SPE western regional/AAPG pacific section joint meeting held in long beach, California, USA, 19–24 May 2003 (SPE 83470).
29. I. D. McAvinchey, Modelling and forecasting in an energy demand system with high and low frequency information, *Economic Modelling* 20 (2002) 207-226
30. Morony John, D. Bergm. (1999), “An Integrated Model of Oil Production”, *The Energy Journal*, Vol. 20, No.1 PP. 105-724.
31. Y. S. Murat, H. Ceylan, Use of artificial neural networks for transport energy demand modeling, *Energy Policy* 34 (2006) 3165–3172.

32. S. S. A. K. JAVEED NIZAMI, A.Z. AL-GARNI, Forecasting electric energy consumption using neural networks, Energy Policy 23 (1995) 1097-1104.
33. S Pokharel, "An econometric analysis of energy consumption in Nepal", Energy Policy (2006) (article in press).
34. K. Pakravan, A model of Oil Production, Development, and Exploration', The Journal of Energy and development, PP. 143-152.
35. R. S. Pindyck, (1978), "The Optimal Exploration and Production of Nonrenewable Resource", Journal of Political Economy, Vol. 86, No.51, PP. 841-862.
36. H. Ramcharran, (2002)", Oil Production Responses to Price Changes : an Empirical application of the Competitive model to OPEC and non-OPEC Countries, Energy Economics 24, PP. 97-106.
37. D.E. Rumelhart, G.E Hinton, Williams, R.J. (1986), Learning internal representation by error propagation. In: Rumelhart, D.E., McClelland, J.L. (Eds.), Parallel Distributed Processing: Explorations in the Microstructure of Cognition, vol. 1. MIT Press, Cambridge, MA, pp. 318-362.
38. R.S. Thompson, J.D. Wright, (1985), Oil Property Evaluation, second ed. Thompson-Wright Associates, Colorado.
39. R.S. Uhler, (1976)", Costs and Supply in Petroleum Exploration : the Case of Alberta', Canadian Journal of Economics, No. 1, PP. 73-90.
40. M.A. Walls, (1991)", Modeling and Forecasting the Supply of Oil and gas, Resources for the Future, Washington DC, USA, Received November 1990, Final Version Received March 1991.
41. P.M. Wong, I.J. Taggart, (1995), Use of neural network methods to predict porosity and permeability of a petroleum reservoir. AI Applied (2), 27-37.
42. G. Zhang, E.B. Pattuwo, M.Y. Hu, A simulation study of artificial networks for nonlinear time series forecasting, Computers and Operation Research, 28(2001) 381-396.



پیوست شماره ۱

الف. جداول آماری

PKERS	POGAS	PGASOL	CKORR	CKERS	COGAS	CGASOL	سال
۲/۵	۲/۴	۶	۴۲۹۶	۳۷۸۷	۵۲۶۴	۲۳۴۶	۱۳۵۳
۲/۵	۲/۴	۶	۴۹۸۵	۴۷۱۴	۶۳۲۳	۳۴۲۰	۱۳۵۴
۲/۵	۲/۴	۶	۵۶۰۴	۵۱۵۰	۷۵۱۷	۳۷۷۵	۱۳۵۵
۲/۵	۲/۴	۸	۶۱۴۷	۵۹۳۶	۹۳۹۸	۴۶۶۶	۱۳۵۶
۲/۵	۲/۴	۱۰	۵۹۸۴	۵۹۲۵	۹۸۱۳	۵۰۷۸	۱۳۵۷
۲/۵	۲/۴	۱۰	۶۳۲۱	۷۳۵۱	۹۷۷۴	۵۷۷۰	۱۳۵۸
۴	۲/۴	۳۰	۷۴۴۴	۵۶۹۲	۹۶۱۷	۴۸۴۴	۱۳۵۹
۴	۲/۴	۳۰	۸۳۵۹	۵۱۳۲	۱۰۴۲۳	۴۴۷۴	۱۳۶۰
۴	۲/۴	۳۰	۸۵۶۳	۶۰۹۵	۱۲۰۱۴	۴۵۸۲	۱۳۶۱
۴	۲/۴	۳۰	۹۸۸۴	۷۹۳۶	۱۴۳۷۷	۶۰۲۰	۱۳۶۲
۴	۲/۴	۳۰	۱۱۱۱۴	۷۷۵۶	۱۵۵۷۹	۶۶۷۶	۱۳۶۳
۴	۲/۴	۳۰	۱۱۶۶۳	۸۴۶۰	۱۸۱۳۸	۷۲۷۳	۱۳۶۴
۴	۲/۴	۳۰	۱۲۰۱۴	۵۹۹۷	۱۶۸۸۸	۶۸۰۵	۱۳۶۵
۴	۴	۳۰	۱۱۲۵۲	۷۵۰۸	۱۸۳۴۹	۷۲۶۱	۱۳۶۶
۴	۴	۳۰	۱۱۵۶۲	۷۴۱۱	۱۸۱۲۴	۷۲۳۶	۱۳۶۷
۴	۴	۳۰	۱۲۲۸۵	۸۷۷۷	۱۷۷۱۳	۷۶۵۷	۱۳۶۸
۴	۴	۵۰	۱۲۵۲۵	۸۲۹۰	۱۸۷۲۳	۸۲۸۱	۱۳۶۹
۴	۱۰	۵۰	۱۲۸۴۲	۸۶۸۰	۲۰۱۵۳	۸۹۹۱	۱۳۷۰
۱۵	۱۰	۵۰	۱۳۹۳۰	۱۰۴۴۱	۲۰۸۸۲	۹۷۷۷	۱۳۷۱
۱۵	۱۰	۵۰	۱۴۰۰۰	۱۰۸۸۰	۲۱۹۱۹	۱۰۷۲۹	۱۳۷۲
۱۵	۱۰	۵۰	۱۵۳۵۶	۱۰۸۲۸	۲۲۷۰۸	۱۱۴۱۰	۱۳۷۳
۲۰	۲۰	۱۰۰	۱۴۸۰۹	۱۰۴۸۴	۲۱۸۱۶	۱۱۴۴۶	۱۳۷۴
۳۰	۳۰	۱۳۰	۱۵۷۴۳	۱۱۱۴۸	۲۲۸۷۳	۱۲۰۵۶	۱۳۷۵
۴۰	۴۰	۱۶۰	۱۶۱۰۷	۱۰۶۱۶	۲۳۴۸۰	۱۲۶۶۷	۱۳۷۶
۶۰	۶۰	۲۰۰	۱۳۶۲۵	۹۹۵۷	۲۳۲۸۵	۱۳۷۶۲	۱۳۷۷
۱۰۰	۱۰۰	۳۵۰	۱۳۱۹۲	۹۴۹۱	۲۳۰۲۷	۱۴۲۸۷	۱۳۷۸
۱۱۰	۱۱۰	۴۰۰	۱۴۴۴۶	۹۳۵۰	۲۴۳۵۲	۱۵۵۲۴	۱۳۷۹
۱۲۰	۱۲۰	۴۵۰	۱۵۲۰۸	۸۹۵۳	۲۵۲۱۴	۱۶۷۲۲	۱۳۸۰
۱۳۰	۱۳۰	۵۰۰	۱۴۴۵۱	۸۶۸۱	۲۵۸۴۷	۱۸۴۴۰	۱۳۸۱
۱۶۰	۱۶۰	۶۵۰	۱۳۶۳۲	۸۳۶۹	۲۶۲۳۴	۲۰۶۹۹	۱۳۸۲
۱۷۶	۱۷۶	۶۰۰	۱۳۹۲۷	۸۶۹۹	۳۰۶۲۵	۲۳۰۷۳	۱۳۸۳
۱۹۳	۱۹۳	۸۰۰	۱۴۱۹۹	۸۹۴۱	۳۶۰۸۴	۲۵۹۶۴	۱۳۸۴

فصلنامه مطالعات اقتصاد انرژی

سال	GASCAR	MOTORS	AVGAGE	VATRA	OILCAR	CPI
۱۳۵۳	۳۲۹۰۰۹	۵۷۴۳۲	۳/۹۱۵۸	۷۲۷۸/۸	۲۱۸۸۵۶	۱/۵
۱۳۵۴	۵۴۲۸۹۹	۹۳۰۵۱	۳/۳۷۳۱	۸۸۳۵/۱	۲۷۰۲۴۲	۱/۷
۱۳۵۵	۷۷۴۵۶۸	۷۳۹۳۴	۳/۳۶۴۲	۸۸۹۷	۳۱۷۰۳۸	۱/۹
۱۳۵۶	۸۶۲۸۰۵	۱۰۴۸۷۵	۴/۰۲۰۱	۸۳۱۹/۸	۵۳۱۹۳۴	۲/۲
۱۳۵۷	۱۰۶۳۳۲۸	۴۹۹۶۸	۴/۲۶۲	۱۱۵۱۳/۱	۵۵۳۰۰۶	۲/۷
۱۳۵۸	۱۱۵۷۸۵۰	۳۸۹۳۰	۴/۹۱۴۱	۱۳۳۹۸/۷	۵۵۸۸۶۱	۳
۱۳۵۹	۱۲۵۱۸۵۴	۱۲۵۷۱۳	۵/۵۴۵۱	۱۴۹۲۸/۷	۵۶۷۹۸۲	۳/۳
۱۳۶۰	۱۳۶۲۴۳۹	۱۶۴۷۹۹	۶/۰۹۵	۱۰۹۵۰/۹	۵۸۱۲۰۷	۴/۱
۱۳۶۱	۱۴۶۲۰۶۲	۱۶۴۰۲۲	۶/۶۷۹۷	۱۰۵۰۵/۳	۶۰۰۱۰۶	۵
۱۳۶۲	۱۶۳۹۹۴۸	۹۵۰۴۹	۶/۹۵۵۱	۱۲۲۵۷/۷	۶۳۸۰۴۹	۶
۱۳۶۳	۱۸۱۳۵۳۶	۷۶۲۰۴	۷/۲۸۹۴	۱۳۱۸۳/۳	۶۷۱۰۷۱	۶/۹
۱۳۶۴	۱۹۰۱۹۱۶	۱۰۲۲۴۸	۷/۹۵۰۷	۱۳۷۴۴/۷	۶۹۳۸۷۲	۷/۶
۱۳۶۵	۱۹۴۶۰۹۶	۱۲۰۵۱۰	۸/۷۷۰۲	۱۲۰۵۸/۲	۷۰۱۲۹۵	۸/۱
۱۳۶۶	۱۹۷۶۹۱۶	۱۵۱۵۲۰	۹/۶۳۳۵	۹۸۳۲	۷۰۷۰۱۵	۱۰
۱۳۶۷	۲۰۰۰۰۴۸	۱۶۲۵۳۸	۱۰/۵۲۲	۹۹۳۰/۳	۷۱۲۷۴۳	۱۲/۸
۱۳۶۸	۲۰۱۸۳۰۵	۱۵۳۶۷۳	۱۱/۴۲۷	۱۰۷۷۷/۴	۷۱۸۹۰۱	۱۶/۵
۱۳۶۹	۲۰۶۴۱۷۰	۱۳۱۰۰۶	۱۲/۱۷۳	۱۱۷۸۱/۲	۷۳۲۶۸۷	۱۹/۴
۱۳۷۰	۲۱۴۹۵۶۹	۱۶۰۰۹۸	۱۲/۶۸۹	۱۱۸۶۹/۴	۷۵۵۴۹۲	۲۱/۱
۱۳۷۱	۲۲۳۷۴۳۰	۱۷۲۴۲۴	۱۳/۱۹۱	۱۲۳۱۷/۸	۸۰۵۳۴۹	۲۵/۲
۱۳۷۲	۲۲۹۴۸۲۲	۱۹۵۲۲۱	۱۳/۸۶۱	۱۴۲۹۵	۸۲۳۱۵۰	۳۰/۴
۱۳۷۳	۲۳۵۲۱۵۷	۲۳۹۳۷۶	۱۴/۵۲۳	۱۶۰۰۲/۴	۸۳۷۸۴۷	۲۸/۲
۱۳۷۴	۲۴۳۵۵۴۵	۳۰۷۳۳۹	۱۵/۰۲۶	۱۷۵۵۴/۸	۸۴۷۱۲۵	۵۴/۳
۱۳۷۵	۲۵۴۶۰۶۱	۳۷۹۷۸۹	۱۵/۳۷۴	۲۰۱۹۹	۸۶۳۲۷۳	۸۱/۲
۱۳۷۶	۲۶۹۴۷۳۱	۴۵۲۲۳۹	۱۵/۵۲۶	۲۰۵۷۵/۶	۸۸۷۵۸	۱۰۰
۱۳۷۷	۲۸۶۴۵۲۱	۵۲۹۶۸۴	۱۵/۶۰۵	۲۱۲۱۳/۶	۹۲۵۷۴۷	۱۲۰
۱۳۷۸	۳۰۶۱۵۱۹	۵۹۰۳۳۲/۸	۱۵/۶۰۱	۲۳۶۰۸/۳	۹۶۹۲۶۵	۱۴۶/۴
۱۳۷۹	۳۳۱۸۷۵۷	۶۵۷۹۲۵/۹	۱۵/۳۹۲	۲۵۰۷۱/۵	۱۰۰۷۹۸۱	۱۵۹/۷
۱۳۸۰	۳۶۶۲۱۲۷	۷۳۳۲۵۸/۴	۱۴/۹۴۹	۲۵۳۲۲/۲	۱۰۴۴۸۰	۱۷۷/۹
۱۳۸۱	۴۱۸۱۱۵۴	۸۱۷۲۱۶/۵	۱۴/۰۹۳	۲۵۵۷۵/۴	۱۰۵۸۸۶۸	۲۰۱
۱۳۸۲	۴۹۱۲۶۵۰	۹۱۰۷۸۷/۸	۱۲/۹۹۵	۲۷۱۰۹/۹	۱۰۸۰۰۲۲	۲۳۸/۲
۱۳۸۳	۵۲۵۶۵۳۵	۱۰۴۷۴۰۶/۰	۱۲/۹۱۷	۳۰۰۹۲/۰	۱۳۷۱۶۲۷	۲۶۱/۷
۱۳۸۴	۵۶۲۴۴۹۲	۱۲۰۴۵۱۶/۹	۱۲/۸۳۹	۳۳۴۰۲/۱	۱۷۴۱۹۶۷	۲۸۷/۶

ب. نمونه ای از برنامه کامپیوتری (که تحت نرم افزار MATLAB اجرا شده است)

```
function [MYC,VL,VC,VU,WL,WC,WU,T,E]=NEURAL(INX,OTC,maxit(
m=10; epsilon=0.01; h=1; alpha=.25; beta=.9; sigma=1; gama=1; gamma=0.05; eta=0.25; t=1;
]P,n]=size(INX;(
for j=1:n for i=1:P X(i,j)=gamma+((INX(i,j)-min(INX(:,j)))/(max(INX(:,j))-min(INX(:,j))))*eta;
end
end for i=1:P TC(i)=gamma+((OTC(i)-min(OTC))/(max(OTC)-min(OTC)))*eta; end
L=X; C=X; U=X; TL=TC; TU=TC; ]P,n]=size(L;( %Step 0: Initilize weights
VL = zeros(n+1,m;( , VC = zeros(n+1,m;( , VU = zeros(n+1,m;( , WL = zeros(m+1,1;( WC =
zeros(m+1,1;(
WU = zeros(m+1,1;( deltaVL=zeros(n+1,m;( deltaVC=zeros(n+1,m;( deltaVU=zeros(n+1,m;(
deltaWL=zeros(m+1,1;(
deltaWC=zeros(m+1,1;( deltaWU=zeros(m+1,1;( %Step 1: Feedforward for k=1:maxit for p=1:P;
XL=[1,L(p;( ; XC=[1,C(p;( ; XU=[1,U(p;( ;
for i=1:n+1 for j=1:m a=sort([VL(i,j) VC(i,j) VU(i,j);( VL(i,j)=a(1;(
VC(i,j)=a(2;( VU(i,j)=a(3;(
end end for j=1:m+1 a=sort([WL(j) WC(j) WU(j);( (WL(j)=a(1;(
WC(j)=a(2;( WU(j)=a(3;(
end lambdaL=zeros(n+1,m;( lambdaC=zeros(n+1,m;( lambdaU=zeros(n+1,m;(
SL=zeros(n+1,m;(
SC=zeros(n+1,m;( SU=zeros(n+1,m;( for i=1:n+1 for j=1:m if VL(i,j)>=0,
lambdaL(i,j)=1;
end
if VC(i,j)>=0, lambdaCL(i,j)=1; end if VU(i,j)>=0,
lambdaU(i,j)=1; end
SL(i,j)=(lambdaL(i,j)*VL(i,j)+(1-lambdaL(i,j))*VU(i,j))*XL(i);(
SC(i,j)=(lambdaC(i,j)*VC(i,j)+(1-lambdaC(i,j))*WC(i,j))*XC(i);(
SU(i,j)=(lambdaU(i,j)*WU(i,j)+(1-lambdaU(i,j))*WL(i,j))*XU(i);(end end
NETZL=sum(SL,1;(
ZL=zeros(1,m;( NETZC=sum(SC,1;( ZC=zeros(1,m;( NETZU=sum(SU,1;(
ZU=zeros(1,m;( for j=1:m;
ZL(j)=1/(1+exp(-sigma*NETZL(j);( ZC(j)=1/(1+exp(-sigma*NETZC(j);(
ZU(j)=1/(1+exp(-sigma*NETZU(j);(
End ZL=[ZL,1;( etaL=zeros(m+1,1;( RL=zeros(1,m+1;( ZC=[ZC,1;(
etaC=zeros(m+1,1;( RC=zeros(1,m+1;(
ZU=[ZU,1;( etaU=zeros(m+1,1;( RU=zeros(1,m+1;( for j=1:m+1, if WL(j)>=0,
etaL(j)=1; end if WC(j)>=0,
etaC(j)=1; end if WU(j)>=0, etaU(j)=1; end
```

```

RL(j)=(etaL(j)*WL(j)+(1-etaL(j))*WU(j))*ZL(j); RC(j)=(etaC(j)*WC(j)+(1-
etaC(j))*WC(j))*ZC(j);
RU(j)=(etaU(j)*WU(j)+(1-etaU(j))*WL(j))*ZU(j); end NETYL=sum(RL); YL=1/(1+exp(-
sigma*NETYL);
NETYC=sum(RC); YC=1/(1+exp(-sigma*NETYC); NETYU=sum(RU); YU=1/(1+exp(-
sigma*NETYU); (% Updating Weights9
etaL=zeros(m+1,1); etaU=zeros(m+1,1); etaC=zeros(m+1,1); deltaPhL=2*(h*YC+(1-
h)*YL-(h*TC(p)+(1-h)*TU(p)))*sigma*(h*YC+(1-h)*YL*(1-(h*YC+(1-h)*YL); deltaPL=2*(YL-
TL(p))*sigma*(YL*(1-YL); deltaPhU=2*(h*YC+(1-h)*YU-(h*TC(p)+(1-
h)*TL(p)))*sigma*(h*YC+(1-h)*YU*(1-(h*YC+(1-h)*YU); deltaPU=2*(YU-
TU(p))*sigma*(YU*(1-YU); if h*YC+(1-h)*YL<=h*TC(p)+(1-h)*TU(p, epsilon1=epsilon;
else epsilon1=gama; end if h*YC+(1-h)*YU>=h*TC(p)+(1-h)*TL(p,
epsilon2=epsilon; else epsilon2=gama;
End for j=1:m+1, if WL(j)>=0, etaL(j)=1; end
DWL(j)=(deltaPL+epsilon1*deltaPhL*(1-h))*(etaL(j)*ZL(j)+(1-etaL(j))*ZU(j);
if WU(j)>=0, etaU(j)=1; end
DWU(j)=(deltaPU+epsilon2*deltaPhU*(1-h))*(etaU(j)*ZU(j)+(1-etaU(j))*ZL(j);
if WC(j)>=0, etaC(j)=1; end
DWC(j)=(epsilon1*deltaPhL+epsilon2*deltaPhU)*h*(etaC(j)*ZC(j)+(1-etaC(j))*ZC(j);
end lambdaL=zeros(n+1,m); lambdaC=zeros(n+1,m); lambdaU=zeros(n+1,m);
etaL=zeros(m+1,1); etaC=zeros(m+1,1); etaU=zeros(m+1,1); zetaL=zeros(m+1,1);
zetaC=zeros(m+1,1); zetaU=zeros(m+1,1); for i=1:n+1 for j=1:m if VL(i,j)>=0,
lambdaL(i,j)=1; end if WL(j)>=0, etaL(j)=1; end
if WU(j)<=0, zetaU(j)=1; end DVL(i,j)=(deltaPL+epsilon1*deltaPhL*(1-
h))*(etaL(j)*WL(j)+zetaL(j)*WU(j))*sigma*(ZL(j))*(1-ZL(j))*(lambdaL(i,j)*XL(i)+(1-
lambdaL(i,j))*XU(i);
if VU(i,j)>=0, lambdaU(i,j)=1; end if WU(j)>=0, etaU(j)=1;
end if WL(j)<=0, zetaL(j)=1; end
DVU(i,j)=(deltaPU+epsilon2*deltaPhU*(1-h))*(etaU(j)*WU(j)+zetaU(j)*WL(j))*sigma*(ZU(j))*(1-
ZU(j))*(lambdaU(i,j)*XU(i)+(1-lambdaU(i,j))*XL(i);
if VC(i,j)>=0, lambdaC(i,j)=1; end if etaC(j)>=0, etaC(j)=1;
end
if zetaC(j)<=0, zetaC(j)=1; end
DVC(i,j)=(epsilon1*deltaPhL+epsilon2*deltaPhU)*h*(etaC(j)*WC(j)+zetaC(j)*WC(j))*sigma*(ZC(j))*
(1-ZC(j))*(lambdaC(i,j)*XC(i)+(1-lambdaC(i,j))*XC(i);
end end deltaWL=-alpha*DWL'+beta*deltaWL; deltaWC=-alpha*DWC'+beta*deltaWC;
deltaWU=-alpha*DWU'+beta*deltaWU;
deltaVL=-alpha*DVL+beta*deltaVL; deltaVC=-alpha*DVC+beta*deltaVC; deltaVU=-
alpha*DVU+beta*deltaVU;

```

## فصلنامه مطالعات اقتصاد انرژی

```

VL=VL+deltaVL; VC=VC+deltaVC; VU=VU+deltaVU; WL=WL+deltaWL;
WC=WC+deltaWC;
WU=WU+deltaWU; E(p)=(TL(p)-YL)^2+(TU(p)-YU)^2+epsilon1*(h*YC+(1-h)*YL-h*TC(p)-(1-
h)*TU(p))^2+epsilon2*(h*YC+(1-h)*YU-h*TC(p)-(1-h)*TL(p))^2; end T(k)=t; E(k)=sum(E;
t=t+1; end for i=1:n+1 for j=1:m a=sort([VL(i,j) VC(i,j) VU(i,j);[
VL(i,j)=a(1; VC(i,j)=a(2; VU(i,j)=a(3; end end for j=1:m+1,
a=sort([WL(j) WC(j) WU(j);[ WL(j)=a(1; WC(j)=a(2; WU(j)=a(3;
end for p=1:P;
XL=[1,L(p) ;(:;XC=[1,C(p) ;(:;XU=[1,U(p);(:; lambdaL=zeros(n+1,m;
lambdaC=zeros(n+1,m;
lambdaU=zeros(n+1,m; SL=zeros(n+1,m; SC=zeros(n+1,m; SU=zeros(n+1,m;
for i=1:n+1 for j=1:m if VL(i,j)>=0, lambdaL(i,j)=1; end if
VC(i,j)>=0,
lambdaCL(i,j)=1; end if VU(i,j)>=0, lambdaU(i,j)=1; end
SL(i,j)=(lambdaL(i,j)*VL(i,j)+(1-lambdaL(i,j))*VU(i,j))*XL(i;
SC(i,j)=(lambdaC(i,j)*VC(i,j)+(1-lambdaC(i,j))*VC(i,j))*XC(i;
SU(i,j)=(lambdaU(i,j)*VU(i,j)+(1-lambdaU(i,j))*VL(i,j))*XU(i; end end
NETZL=sum(SL,1; ZL=zeros(1,m; NETZC=sum(SC,1) ;ZC=zeros(1,m;
NETZU=sum(SU,1;
ZU=zeros(1,m; for j=1:m, ZL(j)=1/(1+exp(-sigma*NETZL(j);(( ZC(j)=1/(1+exp(-
sigma*NETZC(j);((
ZU(j)=1/(1+exp(-sigma*NETZU(j);(( end ZL=[ZL,1; etaL=zeros(m+1,1;
RL=zeros(1,m+1) ;(ZC=[ZC,1;
etaC=zeros(m+1,1; RC=zeros(1,m+1; ZU=[ZU,1] ;etaU=zeros(m+1,1;
RU=zeros(1,m+1;
for j=1:m+1, if WL(j)>=0, etaL(j)=1; end if WC(j)>=0, etaC(j)=1;
end if WU(j)>=0,
etaU(j)=1; end RL(j)=(etaL(j)*WL(j)+(1-etaL(j))*WU(j))*ZL(j;
RC(j)=(etaC(j)*WC(j)+(1-etaC(j))*WC(j))*ZC(j;
RU(j)=(etaU(j)*WU(j)+(1-etaU(j))*WL(j))*ZU(j; end NETYL=sum(RL;
YL(p)=1/(1+exp(-sigma*NETYL;((
NETYC=sum(RC; YC(p)=1/(1+exp(-sigma*NETYC;(( NETYU=sum(RU;
YU(p)=1/(1+exp(-sigma*NETYU;((
End for i=1:P MYC(i)=(YC(i)-gamma)/eta)*(max(OTC)-min(OTC))+min(OTC); end
hold on plot(INX(:,1),OTC,'b'. plot(INX(:,1),MYC,'r').

```