

مدل ترکیبی شبکه عصبی با الگوی ARIMA جهت پیش بینی مالیات بر ارزش افزوده بر مصرف بنزین در ایران

یگانه موسوی جهرمی^۱

الهام غلامی^۲

تاریخ پذیرش: ۱۳۹۳/۴/۱۱

تاریخ دریافت: ۱۳۹۲/۱۲/۷

چکیده

یکی از مسائل مهم هنگام بودجه ریزی، دسترسی به درآمدهای قابل تحقق است که این موضوع مستلزم پیش بینی‌های دقیق از انواع درآمدها در آینده می باشد. یکی از منابع درآمدی پر اهمیت دولت مالیات بوده که در این مقاله، پیش بینی مالیات بر ارزش افزوده ناشی از مصرف بنزین مدنظر قرار گرفته است. هدف اصلی، دستیابی به روشی کارا جهت پیش بینی مصرف بنزین و مالیات بر ارزش افزوده ناشی از آن در ایران می باشد. در این مقاله، برای پیش بینی مصرف بنزین، از یک الگوی ترکیبی روش شبکه عصبی چندلایه (MLP) با الگوی خودتوضیح میانگین متحرک انباشته (ARIMA) استفاده شده است. سپس با تأیید عملکرد مناسب این روش در مقایسه با روش ARIMA از طریق اعمال نرخ‌های مالیات بر مصرف پیش بینی شده بنزین، مالیات بر ارزش افزوده ناشی از مصرف بنزین در کشور به دست آمده است. نتایج نشان می دهد که طی سال‌های ۱۳۹۲ الی ۱۳۹۵، مالیات بر ارزش افزوده از این محل، به طور متوسط در حدود ۳۱/۶ درصد رشد خواهد داشت.

واژگان کلیدی: مالیات بر ارزش افزوده، مصرف بنزین، شبکه عصبی چندلایه، روش ARIMA، روش ترکیبی

طبقه بندی JEL: R22, H24, C45

۱. دانشیار گروه اقتصاد دانشگاه پیام نور

۲. استادیار، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، دانشکده مدیریت و اقتصاد، گروه اقتصاد، تهران

mosavi@pnu.ac.ir

elham_gholami4@yahoo.com

۱. مقدمه

پیشگویی شرایط و حوادث آینده، پیش بینی نامیده شده و چگونگی انجام این عمل، پیش‌بینی کردن تعریف می‌شود (دهمرده و همکاران، ۱۳۹۰: ۷). پیش بینی فرآیندی برای تصمیم‌گیری، برنامه‌ریزی و فرموله کردن سیاست‌های جدید و آماده شدن برای رویارویی با آثار ناشی از آن است. پیش بینی قدرت و اختیار سیاستگذاران و مردم را افزایش می‌دهد، زیرا می‌توان متغیرهای فعلی را به منظور تغییر آینده یا آماده شدن برای یک سیاست جدید پیش‌بینی و در صورت لزوم اصلاح کرد.

پیش بینی برخی از متغیرهای اقتصادی، یکی از موضوعات حائز اهمیت برای برنامه‌ریزی در سطح ملی و منطقه‌ای محسوب می‌شود. در این بین، پیش بینی دقیق درآمدهای مالیاتی به عنوان یکی از منابع پایدار درآمدی می‌تواند هنگام بودجه‌ریزی و تخصیص بهینه منابع مفید فایده باشد. بنابراین، برای تحقق بخشیدن به این موضوع و دستیابی به اطلاعاتی قابل اتکاء از درآمدهای مالیاتی، به کارگیری مدل‌های پیش بینی دارای دقت بالا اجتناب ناپذیر می‌باشد. بررسی ادبیات تجربی حاکی از این است که در سال‌های اخیر برای پیش بینی سری‌های زمانی از دو گروه عمده از مدل‌ها استفاده شده است. گروه اول مبتنی بر مدل‌های ریاضی سنتی هستند که از جمله آنها می‌توان به روش خودتوضیح میانگین متحرک انباشته (ARIMA)، مدل فیلتر کالمن و ... اشاره نمود. با وجود اینکه، این روش‌ها در زمینه پیش بینی سری‌های زمانی خطی عملکرد به نسبت خوبی داشته‌اند و نتایج سیاستی مهمی را ارائه می‌دهند، اما به هیچ‌وجه نمی‌توان آنها را برای ارائه تصویری کلی از ساختار غالب سیستم‌های اقتصادی کافی دانست؛ زیرا در جهان واقع، اکثر سیستم‌های اقتصادی که تحت تأثیر بسیاری از متغیرهای غیر اقتصادی مانند عوامل روانی، اجتماعی، سیاستی و فیزیکی نیز هستند، رفتاری غیرخطی از خود به نمایش می‌گذارند.

بنابراین، گروه دوم از مدل‌ها، مدل‌های غیرخطی هستند که قابلیت یادگیری تدریجی به وسیله ورود داده‌های جدید را دارند. یکی از این مدل‌ها، شبکه عصبی مصنوعی می‌باشد. استفاده از روش‌های شبکه عصبی مصنوعی در تحلیل اقتصادی اگرچه رویکرد جدیدی محسوب می‌شود، اما به دلیل کارایی قابل قبول آن، به طور گسترده‌ای در مطالعات تجربی مورد استفاده قرار گرفته است. مک کولچ (McCulloch, 1943) و روزن بلات (Rosenblatt, 1958) پایه‌های اولیه استفاده از ساختار مشابه سیستم‌های شبکه عصبی بدن را در ریاضیات و محاسبات بنا گذاشتند. بعد از تکمیل روش‌های پیشنهادی، شبکه‌های عصبی به عنوان ابزاری قدرتمند در شبیه سازی رفتارهای مختلف در اکثر علوم از جمله علم اقتصاد وارد گردید. در حال حاضر، این روش در مطالعات اقتصادی زیادی در زمینه‌های پیش بینی تورم، مالیات، رشد اقتصادی و ... استفاده می‌شود.

با وجود اینکه هر یک از روش‌های سری زمانی و شبکه عصبی به رغم اینکه به موفقیت‌هایی در

پیش بینی سری‌های زمانی خطی و غیرخطی دست یافته اند، لیکن هیچیک از آنها یک مدل عمومی و مناسب برای تمام شرایط نیست. زیرا مدل‌های سری زمانی ARIMA برای مسائل غیرخطی پیچیده مناسب نیستند و به کارگیری روش شبکه عصبی برای مسائل خطی منتج به نتایج مختلف می‌شود. از طرف دیگر، آگاهی از خصوصیات واقعی سری‌های زمانی در دنیای واقعی کار دشواری است. از این‌رو، در ادبیات جدید برای استفاده از قابلیت‌های مدل‌های مختلف از مدل‌های ترکیبی استفاده می‌شود (Wang and Meng, 2012: 4).

در این مقاله نیز جهت نیل به هدف اصلی یعنی دستیابی به پیش بینی دقیق از مالیات بر ارزش افزوده ناشی از مصرف بنزین، بررسی کارآیی روش سری زمانی و ترکیب شبکه عصبی و سری زمانی در این زمینه، مدنظر قرار گرفته است.

۲. ادبیات موضوع

۲-۱. رویکردی بر نظام مالیات بر ارزش افزوده در ایران و جایگاه بنزین

مالیات بر ارزش افزوده، یک مالیات بر فروش چند مرحله‌ای است که در هر یک از مراحل واردات، تولید، توزیع تا مصرف نهایی بر حسب ارزش افزوده ایجاد شده، به صورت درصدی از آن، در همان مرحله اخذ می‌شود. در این فرایند، خرید کالاها و خدمات واسطه‌ای از پرداخت مالیات معاف می‌شود و بار قانونی مالیاتی آن بر دوش مصرف کننده نهایی است. در واقع، مالیات بر ارزش افزوده از ارزش افزوده بنگاه‌ها، یعنی از مابه‌تفاوت بین عایدی ناشی از فروش کالاها و خدمات و کل هزینه‌هایی که بابت خرید نهاده‌های تولید (به استثنای نیروی انسانی) پرداخت شده است، دریافت می‌شود (موسوی جهرمی، ۱۳۸۶: ۱۵).

این مالیات در مهرماه سال ۱۳۸۷ در ایران لازم الاجرا و یک نرخ عمومی ۳ درصدی برای وضع مالیات بر تمامی کالاها و خدمات مشمول مالیات بر ارزش افزوده در نظر گرفته شد. با این وجود، از آنجا که این مالیات از دید نظری، مالیاتی بر پایه مصرف و مبتنی بر اصل مقصد است، ضمن تأمین درآمد لازم برای دولت، می‌تواند به عنوان ابزاری مناسب جهت اصلاح الگوی مصرف در جامعه نیز مورد استفاده قرار گیرد (غلامی، ۱۳۸۹: ۴). از این‌رو، برخی از کالاها و خدمات در قانون مالیات بر ارزش افزوده ایران به عنوان کالاهای خاص در نظر گرفته شده و با نرخ‌های بالاتری از نرخ عمومی مشمول مالیات قرار گرفتند. از جمله این موارد بنزین است که دلیل رفتار مالیاتی متفاوت با آن (وضع نرخ مالیات ۲۰ درصد) را می‌توان به بالا بودن شدت مصرف این کالا در کشور و به پیامدهای زیست محیطی و همچنین ارزی بری بالای آن نسبت داد.

همچنین، شایان ذکر است که مالیات بر ارزش افزوده موجب افزایش قیمت کالاها و خدمات


مشمول آن مالیات می شود که بر این اساس، بررسی اثرات این نوع مالیات از منظرهای گوناگون، به ویژه از منظر رفاه عمومی و توزیع درآمد، ضرورت می یابد. توجه به این زوایای موضوع در خصوص بنزین و تغییر قیمت آن نه تنها از اهمیت خاصی برخوردار است بلکه از موضوعات مناقشه برانگیز در اقتصاد ایران می باشد که به همین جهت مطالعات متعددی در ارتباط با آن انجام شده است (ر. ک: دادگر و همکاران، ۱۳۸۷). از آنجا که ورود به این حوزه خارج از محدوده هدف مطالعه حاضر است، در مقاله بدان پرداخته نشده است.

۲-۲. روش های پیش بینی سری های زمانی

روش های زیادی برای بررسی آینده های مختلف و پیش بینی های دقیق و محتمل تر متغیرها وجود دارد که گردن^۱ در یک دسته بندی کلی، این روش ها را به کیفی و کمی تفکیک کرده است. به طوریکه روش های کمی خود دربردارنده روش های سری زمانی و مبتنی بر مدل هستند (جنتی، ۱۳۹۰: ۳). در الگوهای سری زمانی که اغلب برای پیش بینی های کوتاه مدت مورد استفاده قرار می گیرند، سعی می شود، رفتار یک متغیر براساس مقادیر گذشته آن متغیر- و احتمالاً مقادیر گذشته سایر متغیرهایی که پیش بینی آنها مد نظر است- توضیح داده شود. این الگوها حتی در مواردی که الگوی اقتصادی زیرساختی مشخصی وجود ندارد، نیز قادر به ارائه پیش بینی هایی دقیق از متغیرهای مورد نظر است (نوفرستی، ۱۳۸۷).

الگوهای سری زمانی را همان طور که در شکل شماره (۱) آمده است، می توان به دو گروه الگوهای خطی و غیر خطی تقسیم نمود (عرب مازار و همکاران، ۱۳۸۷: ۳۹).

شکل ۱. انواع الگوهای سری زمانی



ماخذ: عرب مازار و همکاران، ۱۳۸۷: ۳۹.

با توجه به شکل (۱)، دو الگوی خودتوضیح میانگین متحرک انباشته (ARIMA)^۱ و فضای حالت^۲ جزء الگوهای خطی محسوب می‌شوند. در مقابل، الگوهای سری زمانی غیرخطی از گستردگی بیشتری برخوردار می‌باشند، به طوری که الگوهای شبکه عصبی مصنوعی^۳ در گروه الگوهای سری زمانی غیرخطی عمومی با ناظر^۴ قرار دارند.

۲-۳. الگوی خودتوضیح میانگین متحرک انباشته (ARIMA)

مدل‌های ARIMA که به مدل‌های باکس-جنگیز^۵ نیز معروف اند، از روش‌های معروف مدل سازی در سری‌های زمانی است که عمدتاً برای پیش بینی سری‌های زمانی مورد استفاده قرار می‌گیرد. متدلوژی این روش مبتنی است بر تجزیه و تحلیل تصادفی سری‌های زمانی براساس این فلسفه که

1. Autoregressive Integrated Moving Average Processes
2. State Space
3. Artificial Neural Networks
4. Supervised General Nonlinearity
5. Box-Jenkins models

بگذارید اطلاعات خود سخن بگوید (گجراتی، ۱۳۷۸). در مدل‌های ARMA، ارزش آتی یک متغیر، تابعی خطی از مشاهدات گذشته و جملات خطای تصادفی است. شکل کلی فرایند تولید یک سری زمانی به صورت زیر است:

$$y_t = \theta_0 + \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (1)$$

در رابطه (۱)، y_t ارزش سری زمانی، φ_i ($i=1,2,\dots,p$)، θ_j ($j=1,2,\dots,q$) به ترتیب، پارامترهای مدل میانگین متحرک و مدل خودتوضیح هستند. ε_t یک فرایند تصادفی با میانگین صفر و واریانس σ^2 است. شایان ذکر است، یکی از شرایط لازم برای به کارگیری مدل‌های ARMA، پایایی سری زمانی مورد بررسی است که این موضوع در خصوص متغیرهای اقتصادی به ندرت وجود دارد. از این‌رو، مدل‌های ARMA گسترش یافتند تا حتی در شرایطی که سری‌های زمانی ناپایا باشند، نیز مورد استفاده قرار می‌گیرند. در این حالت مدل‌های ARMA تحت عنوان ARIMA مطرح می‌شوند و درجه جمع بستگی آنها همان درجه جمع بستگی سری زمانی مورد بررسی می‌باشد. فرایند استفاده از این روش شامل چهار مرحله تشخیص، تخمین، کنترل تشخیصی و پیش بینی است. به طوری که بعد از اطمینان از پایا بودن سری زمانی مدنظر، با استفاده از توابع خودهمبستگی^۱ و خودهمبستگی جزئی^۲ و با در نظر داشتن اصل صرفه جویی و معیارهای شوارتز-بیزین^۳، آکائیک^۴ و حنان کوئین^۵، مرتبه مدل، شناسایی و سپس مدل تصریح شده برآورد می‌گردد. بعد از تخمین و تثبیت آن به عنوان مدل نهایی، اقدام به پیش بینی مدل می‌گردد (Grange and Newbold, 1986).

۲-۴. الگوی شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی، چارچوب محاسباتی انعطاف پذیر برای مدل سازی دامنه وسیعی از مسائل غیرخطی هستند (Khashei and Bijari, 2011: 4). از بین انواع شبکه های عصبی، شبکه عصبی پیشخور با یک لایه مخفی، یکی از رایج ترین مدل‌ها برای مدل سازی و پیش بینی سری‌های زمانی محسوب می‌شود. این شبکه عصبی از سه لایه شامل یک لایه ورودی جهت اعمال ورودی‌های مساله، چندلایه مخفی یا پنهان^۶ (حداقل یک لایه) و یک لایه خروجی که نهایتاً پاسخ مساله را ارائه می‌نمایند، تشکیل شده است. روابط بین خروجی و ورودی‌ها در این شبکه به صورت زیر می‌باشد:

1. Auto Correlation Function
2. Partial Auto Correlation Function.
3. Schwarz Criterion
4. Akaike Info Criterion
5. Hannan Quinn Criterion
6. Hidden

$$y_t = \omega_0 + \sum_{j=1}^q \omega_j g(\omega_{0j} + \sum_{i=1}^p \omega_{i,j} y_{t-j}) + e_t \quad (2)$$

در این رابطه، $\omega_j (j = 1, 2, \dots, q)$ و $\omega_{i,j} (i = 0, 1, 2, \dots, p; j = 1, 2, \dots, q)$ پارامترهای مدل و به اصطلاح وزن‌های اتصال دهنده محسوب می‌شوند. به طوری که، p, q به ترتیب، تعداد گره‌های لایه مخفی و لایه ورودی اند (Wang and Meng, 2012: 3). بنابراین، جهت تشکیل یک شبکه عصبی باید وزن‌های اتصال دهنده ورودی‌ها برای ارتباط با نرون‌های هر لایه مشخص باشد که برای این منظور، از طریق آموزش شبکه بهترین ترکیب‌های اتصال تعیین می‌شوند. برای آموزش شبکه نیز معمولاً از روش‌های آموزش باناظر^۱ استفاده می‌شود که رایج‌ترین آنها الگوریتم پس انتشار خطا^۲ است (مستعلی، ۱۳۸۷). به علاوه، تابع سیگموئید^۳ که در اکثر موارد به عنوان تابع انتقال لایه مخفی مورد استفاده قرار می‌گیرد، به صورت زیر است:

$$\text{sig}(x) = \frac{1}{1 + \exp(-x)} \quad (3)$$

از این رو، مدل شبکه عصبی مصنوعی رابطه (۲) در واقع یک نگاشت غیر خطی از مشاهدات گذشته $(y_{t-1}, \dots, y_{t-p})$ به مقادیر آینده y_t است، یعنی:

$$y_t = f(y_{t-1}, \dots, y_{t-p}, \omega) + e_t \quad (4)$$

در رابطه (۴)، ω برداری از تمامی پارامترها و f یک تابع است که از طریق معماری شبکه و وزن‌های اتصال دهنده تعیین می‌گردد.

۳. مطالعات تجربی

بررسی مطالعات تجربی در خصوص مالیات بر ارزش افزوده ناشی از مصرف بنزین حاکی از این است که تاکنون در تعداد معدودی از مطالعات این موضوع مدنظر قرار گرفته است که از آن جمله می‌توان به مطالعه هژبر کیانی و غلامی (۲۰۱۲) اشاره کرد. آنها در مقاله خود برای برآورد مالیات ناشی از بنزین از یک روش دو مرحله‌ای استفاده کردند. بدین ترتیب که در ابتدا پایه مالیاتی با استفاده از توابع تقاضای بنزین برآورد و سپس با اعمال نرخ مالیات مربوطه در پایه برآوردی، مالیات بر ارزش افزوده مدنظر را به دست آوردند. در این مقاله نیز متدولوژی مشابه به کار گرفته شده است. با این تفاوت که روش‌های مورد استفاده برای برآورد و پیش‌بینی روند مصرف بنزین در کشور، روش ترکیبی

1. Supervised Learning
2. Back-Propagation
3. Sigmoid

شبکه عصبی و روش ARIMA است. برای این منظور، برخی از مطالعاتی که از این روش‌ها برای برآورد مصرف انرژی و بخصوص بنزین استفاده نمودند، بیان شده است.

زنگ و همکاران^۱ (Zheng et.al, 2012) در مقاله‌ای برای پیش‌بینی مصرف فرآورده‌های نفتی در چین از سه روش مختلف شامل شبکه عصبی مصنوعی با الگوریتم پس انتشار، مدل‌های مبتنی بر رشد و مدل لجستیک استفاده نمودند. این مدل‌ها براساس خوبی برازش و دقت در پیش‌بینی مورد ارزیابی قرار گرفتند.

وانگ و منگ (Wang and Meng, 2012) در مقاله خود با اشاره به مزیت و معایب هر یک از روش‌های خطی و غیرخطی سری‌های زمانی، مصرف انرژی در چین را برای دوره ۱۹۸۰ الی ۲۰۰۸ با استفاده از مدل‌های خودتوضیح میانگین متحرک (ARMA)، شبکه عصبی مصنوعی و همچنین ترکیبی از این دو الگو پیش‌بینی نمودند. ارزیابی قدرت این الگوها بر اساس معیارهای عملکرد بیانگر تأثیرگذاری بیشتر الگوی ترکیبی در بهبود نتایج حاصل از پیش‌بینی مصرف انرژی در دوره مورد بررسی بوده است.

لی و همکاران (Zheng et.al, 2010) در مقاله خود با هدف انتخاب بهترین و کاراترین مدل برای پیش‌بینی، مدل‌های مختلفی با در نظر گرفتن ملاحظات تئوریک و کاربردی برای پیش‌بینی مصرف بنزین در بخش حمل و نقل (سواری) تصریح نمودند. این مدل‌ها عبارتند از: مدل روند خطی، مدل روند درجه دوم، مدل روند نمایی، مدل خطی هلت، مدل هلت-ویلتر، مدل تعدیل جزئی و فرایند خودتوضیح میانگین متحرک (ARMA). سپس هر یک از این مدل‌ها برآورد و برای بررسی اعتبار آنها، تفاوت‌های بین مشاهدات پیش‌بینی شده و واقعی تقاضای بنزین با هم مقایسه و در نهایت، روند مصرف بنزین برای دوره زمانی ۲۰۰۷ الی ۲۰۲۰ براساس بهترین مدل منتخب، یعنی مدل روند درجه دوم، پیش‌بینی شده است.

در ایران نیز افتخاری (۱۳۶۲) در مقاله خود تابع مصرف فرآورده‌های نفتی ایران را با استفاده از روش‌های سری زمانی و برای سال‌های ۱۳۴۰ الی ۱۳۶۱ برآورد نموده و براین اساس، مصارف فرآورده‌های نفتی را برای سال‌های ۱۳۶۲ الی ۱۳۶۷ پیش‌بینی کرده است. وی در مطالعه خود به این نتیجه رسید که روش‌های آماری مبتنی بر رشد، برای برآوردهای بلندمدت و میان مدت کارایی چندانی ندارند و دلیل اصلی این نتیجه را به عدم لحاظ متغیرهایی مانند قیمت و درآمد که توضیح دهنده‌های خوبی برای رفتار مصرفی جامعه هستند، نسبت داد.

بغزبان و نصرآبادی (۱۳۸۵) در مقاله‌ای با اشاره به اهمیت پیش‌بینی‌های دقیق مصرف انرژی به خصوص بنزین و برنامه‌ریزی صحیح در هدایت مصرف آنها، به پیش‌بینی فرآورده‌های نفتی در ایران

1. Liu and et.al

برای سال‌های ۱۳۸۶ الی ۱۴۰۰ پرداخته‌اند. در این مقاله دو روش شامل سیستم معادلات همزمان و شبکه‌های عصبی به کار گرفته شده و متوسط رشد سالانه مصرف بنزین، نفت گاز، نفت سفید و نفت کوره در دوره مدنظر براساس سیستم معادلات همزمان به ترتیب، معادل ۸/۹، ۰/۹، ۰/۱ و ۰/۸ درصد و براساس مدل شبکه عصبی فازی با الگوریتم پس انتشار به ترتیب، معادل ۱۰/۱، ۱/۱، ۰/۷ و ۱/۱ درصد پیش بینی شده است.

امین ناصری و کوچک زاده (۱۳۸۴ و ۱۳۸۵) در دو مطالعه مجزا، برای پیش بینی ماهانه مصرف نفت سفید (با توجه به چرخشی بودن روند آن) و مصرف بنزین کشور از روش شبکه‌های عصبی مصنوعی استفاده نموده‌اند.


همچنین توسط جنتی (۱۳۹۰) نیز در مقاله‌ای مصرف حامل‌های انرژی (فرآورده‌های نفتی) شامل نفت سفید، نفت کوره، گاز مایع، بنزین و نفت گاز و همچنین گاز طبیعی در کل اقتصاد با استفاده از روش ARIMA پیش بینی شده است. دوره مورد مطالعه سال‌های ۱۳۷۰ الی ۱۳۸۹ بوده که سه سال آخر جهت قیاس پیش بینی الگو با مقادیر واقعی در نظر گرفته شد. در نهایت با توجه به کاهش مصرف حامل‌های انرژی و گاز طبیعی طی سال‌های ۱۳۸۹ و ۱۳۹۰ و بیان صرفه جویی ناشی از اصلاح قیمت حامل‌های انرژی مطابق با قانون هدفمند کردن یارانه‌ها به عنوان دلیل آن، مصرف برای سال‌های ۱۳۹۱ الی ۱۳۹۴ پیش‌بینی شده است. نتایج نشان دهنده کاهش ۳۰ درصدی در مصرف فرآورده‌های نفتی و کاهش ۲۵ درصدی در مصرف گاز طبیعی تا پایان سال ۱۳۹۴ (همزمان با اتمام برنامه پنجم توسعه) بوده است.

همان طور که مشاهده می‌شود در تمامی مطالعات انجام شده در داخل، پیش بینی مصرف بنزین با استفاده از یکی از دو روش ARIMA و شبکه عصبی مدنظر بوده است و در هیچیک ترکیب این دو روش مورد استفاده قرار نگرفته است.

۴. تصریح الگوی پیشنهادی تحقیق برای پیش بینی مالیات بر ارزش افزوده ناشی از مصرف بنزین
درآمد مالیاتی هر منبع مالیاتی از دو جزء اصلی یعنی پایه مالیات و نرخ مالیات تشکیل شده است. با توجه به اینکه نرخ مالیات در قانون تعیین شده و همواره ثابت است، بنابراین برآورد و پیش بینی هر منبع مالیاتی مستلزم در اختیار داشتن پایه مالیاتی است. براین اساس، برآورد مالیات بر ارزش افزوده ناشی از مصرف بنزین نیز مستلزم شناسایی پایه مالیاتی مناسب است. از آنجا که مالیات بر ارزش افزوده در حال اجراء در ایران از نوع مصرفی است و مالیات بر ارزش پولی کالاها و خدمات وضع می‌گردد، پایه مالیات بر ارزش افزوده ناشی از مصرف بنزین را می‌توان مخارج مصرفی بنزین تعریف کرد. براین اساس، برای دستیابی به پیش بینی دقیق مالیات بر ارزش افزوده ناشی از مصرف بنزین می‌باید پایه مالیات مذکور با دقت بالا

پیش بینی گردد که برای این منظور از یک روش ترکیبی استفاده شده است. سیستم ترکیبی مدنظر در این مقاله، در واقع ترکیبی از روش شبکه عصبی چندلایه با مدل سری زمانی ARIMA است که چارچوب کلی آن در شکل شماره (۲) ارائه شده است.

شکل ۲. الگوی ترکیبی روش شبکه عصبی با مدل سری زمانی ARIMA



اولین گام در به کارگیری روش پیشنهادی، استفاده از الگوی ARIMA برای مدل سازی جزء خطی سری زمانی مورد بررسی و به دست آوردن پیش بینی هایی از آن برای سال های مدنظر است. همان طور که بیان شد، الگوی ARIMA مبتنی بر روابط خطی پارامترهای سیستم است و براین اساس می تواند روابط خطی را با عملکرد بالایی پیش بینی نماید، اما در حالتی که روابط غیرخطی باشند، این روش دیگر هیچ قابلیتیتی ندارد. در مقابل، ارزیابی شبکه های عصبی در مطالعات متعدد حاکی از عملکرد مناسب آنها برای مدل سازی روابط غیرخطی است. به همین دلیل، شبکه عصبی در مرحله دوم برای مدل سازی جزء غیرخطی سری زمانی مورد مطالعه در این مقاله و همچنین تمامی روابطی که توسط ARIMA توضیح داده نشده است، استفاده می شود. بنابراین، در گام دوم، پیش

بینی های به دست آمده از طریق الگوی ARIMA در گام اول و همچنین اطلاعات سری زمانی به عنوان ورودی شبکه عصبی مصنوعی منظور می گردد. در گام سوم، شبکه عصبی برای پیش بینی مقادیر آینده سری زمانی مربوطه به کار گرفته می شود.

۵. پیش بینی پایه مالیات بر ارزش افزوده ناشی از مصرف بنزین

۵-۱. مدل سازی روند مصرف بنزین با استفاده از روش ARIMA

از آنجا که شرط به کارگیری این الگوها و دستیابی به پیش بینی های قابل اتکاء مبتنی بر آن، پایا بودن متغیر مورد بررسی است، لذا پایایی روند مصرف بنزین در کشور طی سال های (۱۳۶۰-۱۳۹۱) با استفاده از آزمون دیکی- فولر تعمیم یافته بررسی و نتیجه شده که قدرمطلق آماره آزمون در تفاضل مرتبه اول (۳/۴۶-) بیشتر از قدرمطلق آماره بحرانی (۳-) است. براین اساس، این متغیر در سطح، دارای ریشه واحد بوده و با یک بار تفاضل گیری پایا می گردد.

بعد از بررسی پایایی، تعیین رتبه p, q در الگوی ARIMA حائز اهمیت بوده که برای این منظور از تابع خودهمبستگی (ACF) و تابع خودهمبستگی جزئی (PACF) استفاده شده است. براین اساس، الگوی (۱و۱) ARIMA به عنوان مدل مناسب انتخاب شده است.

شکل ۳. تابع خودهمبستگی و تابع خودهمبستگی جزئی مصرف بنزین

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.548	-0.548	7.2621	0.007
		2	0.135	-0.237	7.7234	0.021
		3	0.042	0.004	7.7698	0.051
		4	0.038	0.152	7.8113	0.099
		5	-0.203	-0.155	9.0526	0.107
		6	0.062	-0.251	9.1763	0.164
		7	-0.102	-0.326	9.5355	0.216
		8	0.140	-0.005	10.265	0.247
		9	-0.153	0.007	11.213	0.261
		10	0.109	-0.007	11.736	0.303
		11	-0.078	-0.210	12.030	0.361
		12	0.111	-0.138	12.696	0.392

برآورد روند مصرف بنزین با استفاده از اطلاعات سال های ۱۳۶۰ الی ۱۳۹۱ با استفاده از الگوی (۱و۱) ARIMA در جدول (۱) ارائه شده است. نتایج حاصل از برآورد حاکی از آن است که ضریب تعیین در این الگو بالا است که نشان دهنده قدرت توضیح دهندگی بسیار بالای آنها می باشد. آماره دوربین- واتسن (D-W) نیز عدم وجود خودهمبستگی پیاپی را در تمامی الگوها نشان می دهد.

جدول ۱. برآورد الگوی سری زمانی مصرف بنزین طی سالهای (۱۳۹۱-۱۳۶۰)

متغیر	ضریب برآوردی	آماره t
C	-۴۱	-۱۲/۱
MA(1)	۱/۹۸	۴/۰۳
AR(1)	-۰/۳۸	-۴/۲۱
D-W	۲/۰۴	-
R ²	۰/۸۵	-

مأخذ: یافته‌های تحقیق

۵-۲. مدل سازی روند مصرف بنزین با استفاده از روش ترکیبی شبکه عصبی و ARIMA برای مدل سازی روند مصرف بنزین یک شبکه عصبی دو لایه‌ای کاملاً متصل به هم با یک لایه مخفی و یک لایه خروجی در نظر گرفته شده است. به طوری که ورودی‌های این شبکه به جای داده‌های واقعی روند مصرف بنزین، پیش بینی‌های حاصل از الگوی (۱و۱) ARIMA است. هنگام به کارگیری شبکه عصبی، انتخاب معماری شبکه حائز اهمیت است. تعداد تأخیر در ورودی شبکه و تعداد نرون‌ها در لایه مخفی با استفاده از شبیه سازی کامپیوتری و براساس مقایسه عملکرد پیش بینی حالت‌های مختلف، انتخاب شدند. معیارهای ارزیابی عملکرد پیش بینی در این مقاله عبارتند از ریشه میانگین مربعات خطا (RMSE)^۱، و متوسط درصد خطای مطلق (MAPE)^۲ که هر یک به صورت زیر تعریف می‌شوند:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (v_t - p_t)^2} \quad (۵)$$

$$MAPE = \sum_{t=1}^n \left| \frac{v_t - p_t}{v_t} \right| \cdot \frac{100}{n} \quad (۶)$$

در روابط (۵) و (۶)، n تعداد دوره پیش بینی، v_t ارزش واقعی سری زمانی در زمان t و p_t ارزش پیش بینی شده سری زمانی است.

نتایج بررسی معیارهای RMSE و MAPE برای دو روش ARIMA و الگوی ترکیبی در جدول (۲) ارائه شده است.

1. Root Mean Square Error
2. Mean Absolute Percentage Error

جدول ۲. انتخاب معماری شبکه براساس معیارهای ارزیابی عملکرد پیش بینی

تعداد نرون لایه ورودی	تعداد نرون لایه خروجی	RMSE_TR	MAPE_TR
۲	۲	۷۰۹/۷۶	۰/۰۲۷
۵	۵	۱۹۸۴/۷	۰/۰۴
۵	۱۵	۲۱۴/۵۶	۰/۰۰۵۸
۱۵	۲	۱۸۸/۱۸	۰/۰۰۴
۲۰	۲۰	۲۹۷۵/۴	۰/۰۴۶

مأخذ: یافته‌های تحقیق

با توجه به نتایج جدول (۲)، بهترین شبکه عصبی به صورت یک شبکه با ۱۵ نرون در لایه ورودی، ۴ نرون در لایه مخفی و ۲ نرون در لایه خروجی شناسایی شده است.

قابل ذکر است، در این شبکه تابع زیگموند ($f(x) = 1/1 + e^x$) و تابع همانی ($f(x) = x$) به ترتیب به عنوان تابع تحریک نرون‌های لایه مخفی و نرون‌های لایه خروجی استفاده شده و برای آموزش شبکه عصبی، تابع هزینه، میانگین مربعات خطای بین مقادیر واقعی و مقادیر به دست آمده از شبکه عصبی و داده‌های آموزشی بوده و روش استاندارد برای کمینه شدن تابع هزینه و در نتیجه آموزش شبکه عصبی، الگوریتم پس انتشار خطا در نظر گرفته شده است. داده‌های مربوط به سال‌های ۱۳۶۸ الی ۱۳۸۵ به عنوان داده‌های آموزش شبکه و سپس از داده‌های ۱۳۸۶ تا ۱۳۹۱ جهت تست شبکه استفاده شد.

۶. ارزیابی عملکرد روش ARIMA و ترکیبی برای پیش بینی پایه مالیاتی


برای نشان دادن کارایی مدل پیش بینی ترکیبی، عملکرد پیش بینی براساس این روش و الگوی ARIMA با به کارگیری معیارهای ارزیابی عملکرد ارائه شده در روابط (۵) و (۶) بررسی و نتایج حاصله در جدول (۳) ارائه و در شکل (۴) نیز روند مصرف واقعی بنزین و همچنین پیش بینی‌های مبتنی بر دو روش مذکور طی سال‌های ۱۳۶۸ الی ۱۳۹۱ تصویر شده است.

جدول ۳. ارزیابی عملکرد پیش بینی روش ARIMA و ترکیبی

روش	RMSE	MAPE
روش ترکیبی پیشنهادی	۱۸۸/۱۸	۰/۰۰۴
ARIMA	۱۳۲۴/۷	۰/۵۷

مأخذ: یافته‌های تحقیق

شکل ۴. روند مصرف بنزین، داده های واقعی، پیش بینی درون نمونه ای با الگوی ARIMA و ترکیبی طی سالهای ۱۳۶۸ الی ۱۳۹۱



با توجه به نتایج به دست آمده، روش ترکیبی، کارایی بیشتری برای پیش بینی در مقایسه با روش ARIMA دارد. از این رو، برای دستیابی به پیش بینی‌های برون نمونه‌ای دقیق از روند مصرف بنزین، از روش ترکیبی پیشنهادی استفاده شده که در جدول (۴) آمده است.

نکته قابل ذکر اینکه پایه مالیات بر ارزش افزوده، مخارج مصرفی بنزین می باشد و بنابراین، پایه مالیات بر ارزش افزوده ناشی از مصرف بنزین طی سال‌های ۱۳۹۲ الی ۱۳۹۵، از حاصل ضرب قیمت بنزین در مصرف آن در این سال‌ها به دست می آید. برای این منظور، قیمت بنزین نیز براساس فرایند مورد استفاده برای پیش بینی مصرف بنزین، یعنی براساس روش ترکیبی شبکه عصبی با ۱۴ نرون در لایه ورودی، ۴ نرون در لایه مخفی و ۲ نرون در لایه خروجی با (۱ و ۰) ARIMA پیش بینی شده که نتایج آن در جدول (۴) آمده است.

جدول ۴. پیش بینی روند مصرف و مخارج مصرفی بنزین برای سال‌های ۱۳۹۲ الی ۱۳۹۵

سال	۱۳۹۲	۱۳۹۳	۱۳۹۴	۱۳۹۵
قیمت بنزین (ریال)	۸۵۲۰	۱۰۰۱۴	۱۲۰۲۰	۱۴۸۴۰
نرخ رشد قیمت بنزین (ریال)	-	۱۷/۵	۲۰	۲۳/۵
مصرف بنزین (میلیون لیتر)	۳۰۲۹۹	۳۶۷۲۵	۴۲۱۲۳	۴۵۰۶۵
نرخ رشد مصرف بنزین	-	۲۱/۲	۱۴/۶	۶/۸
مخارج مصرفی بنزین (میلیارد ریال)	۲۵۸۱۴۷	۳۶۷۷۶۴	۵۰۶۳۱۸	۶۶۸۷۶۵
نرخ رشد مخارج مصرفی بنزین	-	۴۲/۵	۳۷/۷	۳۲/۱

مأخذ: یافته‌های تحقیق

با توجه به نتایج جدول، قیمت بنزین طی سال‌های ۱۳۹۲ الی ۱۳۹۵ با متوسط رشد سالانه ۲۰ درصدی روندی صعودی خواهد داشت؛ در حالی که نتیجه پیش بینی مصرف بنزین نشان می‌دهد که نرخ رشد آن طی سال‌های مذکور کاهش می‌یابد. به همین دلیل، مخارج مصرفی بنزین که در سال ۱۳۹۳ از رشد ۴۲/۵ درصد برخوردار خواهد بود، طی دو سال ۹۵-۱۳۹۴ با کاهش روبرو می‌شود. به این ترتیب، متوسط رشد مخارج مصرفی بنزین در این سال‌ها ۳۷/۳ درصد به دست می‌آید.

۷. پیش بینی مالیات بر ارزش افزوده ناشی از مصرف بنزین

همان‌طور که بیان شد، درآمد مالیات بر ارزش افزوده ناشی از مصرف بنزین از حاصل ضرب نرخ مالیات و پایه مالیاتی به دست می‌آید. نرخ مالیات بر ارزش افزوده بنزین در قانون مالیات بر ارزش افزوده مصوب ۱۳۸۷ معادل ۲۰ درصد در نظر گرفته شده و تاکنون ثابت باقی مانده است. پایه مالیاتی که مخارج مصرفی بنزین در کشور تعریف شد، با استفاده از مدل ترکیبی شبکه عصبی (۱۵ نرون در لایه ورودی، ۲ نرون در لایه مخفی و ۱ نرون در لایه خروجی) و $ARIMA(1,1,1)$ به عنوان کاراترین مدل، پیش بینی و براین اساس، نتایج پیش بینی مالیات بر ارزش افزوده برای سال‌های ۱۳۹۲ الی ۱۳۹۵ در جدول (۵) ارائه شده است.

جدول ۵. پیش بینی مالیات بر ارزش افزوده ناشی از مصرف بنزین برای سال‌های ۱۳۹۲ الی ۱۳۹۵

سال	۱۳۹۲	۱۳۹۳	۱۳۹۴	۱۳۹۵
مخارج مصرفی بنزین (میلیارد ریال)	۲۵۸۱۴۷	۳۶۷۷۶۴	۵۰۶۳۱۸	۶۶۸۱۷۶۵
نرخ مالیات	٪۲۰	٪۲۰	٪۲۰	٪۲۰
مالیات بر بنزین (میلیارد ریال)	۵۱۶۲۹	۷۳۵۵۳	۱۰۱۲۶۴	۱۳۳۷۵۳
نرخ رشد	-	۴۲/۵	۳۷/۷	۳۲/۱

مأخذ: یافته‌های تحقیق

براساس نتایج جدول فوق، که نرخ مالیات بر ارزش افزوده در سال‌های ۱۳۹۲ الی ۱۳۹۵ ثابت در نظر گرفته شد، روند تغییرات و نرخ رشد درآمد مالیات بر ارزش افزوده کاملاً مشابه پایه مالیات می‌باشد. روند مالیات بر ارزش افزوده بنزین طی سال‌های ۱۳۹۲ الی ۱۳۹۵ افزایشی بوده، لیکن نرخ رشد آن از سال ۱۳۹۲ با کاهش همراه شده است. متوسط رشد درآمد مالیات بر ارزش افزوده ناشی از مصرف بنزین طی این سال‌ها ۳۷/۳ درصد می‌باشد.

۸. نتیجه گیری

در ادبیات تجربی برای پیش بینی بسیاری از سری های زمانی از روش ARIMA و شبکه عصبی استفاده شده است، لیکن هر یک از این دو روش با وجود کارایی بالا در پیش بینی، برای انواع خاصی از سری های زمانی مناسب می باشند و از آنجا که ماهیت واقعی یک سری زمانی کاملاً قابل تشخیص نیست، بنابراین استفاده از روش هایی که قابلیت مدل سازی روابط خطی و غیر خطی را داشته باشد، مدلی کارا تر خواهد بود. برای بررسی این ادعا و دستیابی به پیش بینی های دقیق از مالیات بر ارزش افزوده ناشی از مصرف بنزین در ایران، مدل ترکیبی شبکه عصبی و سری زمانی ARIMA پیشنهاد شد. ارزیابی پیش بینی های این مدل و الگوی سری زمانی از پایه مالیات بر ارزش افزوده ناشی از مصرف بنزین (یعنی روند مصرف بنزین)، کارا تر بودن روش پیشنهادی را تأیید نموده است. بنابراین، این مدل می تواند در عمل نیز برای پیش بینی متغیرهای اقتصادی به منظور برنامه ریزی، تبیین استراتژی ها و سیاستگذاری های اقتصادی مورد استفاده قرار گیرد.

بعد از انتخاب مدل کارآمد، پیش بینی های به دست آمده حاصل از آن در خصوص پایه مالیاتی برای پیش بینی مالیات بر ارزش افزوده ناشی از مصرف بنزین، مورد استفاده قرار گرفت. نتایج حاکی از آن است که با وجود افزایش ارزش اسمی مالیات از این محل طی سال های ۱۳۹۲ الی ۱۳۹۵، نرخ رشد آن، طی این سال ها کاهش یافته است.

منابع و مأخذ

- ابونوری، عباسعلی و هیوا شیوه (۱۳۸۵) برآورد تابع تقاضای بنزین در ایران طی دوره (۸۱-۱۳۴۷)؛ فصلنامه پژوهش نامه اقتصادی، دوره ۶، شماره ۳ (پیاپی ۲۲).
- افتخاری، حمید (۱۳۶۲) روش کاربردی پیش بینی و برآورد مصرف فرآورده‌های نفتی در داخل کشور در برنامه‌های میان مدت؛ پایان نامه کارشناسی ارشد، دانشکده اقتصاد دانشگاه شهید بهشتی.
- امین ناصری، محمدرضا و احمد کوچک زاده (۱۳۸۵) بینی پیش ماهانه مصرف بنزین کشور با استفاده از شبکه های عصبی مصنوعی؛ نشریه فرایند نو، سال اول، شماره ۵.
- بغزیان، آلبرت و ابراهیم نصرآبادی (۱۳۸۵) پیش بینی مصرف فرآورده‌های نفتی: مقایسه سیستم معادلات اقتصادسنجی و شبکه‌های عصبی؛ فصلنامه مطالعات اقتصاد انرژی، سال ۳، شماره ۱۰.
- جنتی، بهاره (۱۳۹۰) پیش‌بینی و تحلیل مصرف فرآورده‌های نفتی طی سال‌های ۱۳۹۱ الی ۱۳۹۴ با استفاده از مدل ARIMA؛ اولین کنفرانس بین المللی نفت، گاز، پتروشیمی و نیروگاهی، مرکز همایش‌های بین‌المللی هتل المپیک تهران.
- دادگر، یدالله؛ روح اله نظری و فاطمه مهربانی (۱۳۸۷) تأثیر سیاست های مالی و تکانه های قیمت بنزین بر توزیع درآمد و رفاه در ایران؛ فصلنامه رفاه اجتماعی، سال ۷، شماره ۲۸.
- دهمرد، نظر و همکاران (۱۳۹۰) استفاده از رهیافت‌های شبکه عصبی و مدل های خودرگرسیون در پیش بینی رشد اقتصادی ایران؛ فصلنامه تحقیقات توسعه اقتصادی، شماره نهم
- عرب مازار، عباس و همکاران (۱۳۸۷) الگوهای پیش بینی درآمدهای مالیاتی؛ طرح پژوهشی سازمان امور مالیاتی کشور.
- غلامی، الهام (۱۳۸۹) بررسی تأثیر هدفمندشدن یارانه ها بر درآمد مالیات بر ارزش افزوده؛ فصلنامه اقتصاد کاربردی، سال اول، شماره دوم.
- کوچک زاده، احمد و محمدرضا امین ناصری (۱۳۸۴) پیش بینی ماهانه مصرف نفت سفید کل کشور با استفاده از شبکه عصبی بازگشتی؛ چهارمین کنفرانس بین‌المللی مهندسی صنایع، دانشگاه تربیت مدرس.
- گجراتی، دامودار (۱۳۷۸) مبانی اقتصاد سنجی؛ ترجمه حمید ابریشمی؛ تهران: انتشارات دانشگاه تهران.
- مستعلی مجدآبادی کهنه، مجتبی (۱۳۸۷) نظارت بر خط و خارج خط یک فرایند چند متغیره برای تشخیص شرایط نرمال و وجود خطا در فرایند؛ پایان نامه کارشناسی ارشد در رشته مهندسی برق - کنترل؛ دانشکده مهندسی، دانشگاه شیراز.
- موسوی جهرمی، یگانه (۱۳۷۶) بررسی اقتصادی مالیات بر مصرف؛ رساله دکتری، دانشگاه آزاد اسلامی (علوم و تحقیقات تهران).

موسوی جهرمی، یگانه (۱۳۸۶) راه های فرار مالیاتی در نظام مالیات بر ارزش افزوده و راهکارهای جلوگیری از آن؛ طرح پژوهشی پژوهشکده امور اقتصادی.

نوفرستی، محمد (۱۳۷۸) ریشه واحد و همجمعی در اقتصادسنجی؛ موسسه خدمات فرهنگی رسا. هژبر کیانی، کامبیز؛ غلامی، الهام و جواد نوبخت (۱۳۹۱) برآورد نرخ بهینه مالیات بر ارزش افزوده با استفاده از الگوی دایموند؛ فصلنامه تحقیقات اقتصادی، دوره ۴۷، شماره دوم.

Granger, C.W.J. and Newbold, P. (1986) *Forecasting Economic Time Series*; Academic Press, 2nd. ed.

Hozhabr Kiani, kambiz and gholami, Elham (2012) *Forecasting of the Value Added Tax Revenue from Gasoline Consumption in Iran*; 1st. International Conference on Econometrics, Methods and Applications, Islamic Azad University of Sanandaj, Iran.

Khashei, Mehdi and Bijari, Mehdi (2011) *A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Time Series Forecasting*; Applied Soft Computing, Vol. 11: 2664-75.

Liu, Rongrong et.al. (2012) *A Comparison of Models for Forecasting Petroleum Consumption in China*; 9th OAPS Working Paper Series, Paper No. 2012-037.

Wang, Xiping and Meng, Ming (2012) *A Hybrid Neural Network and ARIMA Model for Energy Consumption Forecasting*; Journal of Computers, Vol. 7, No.5.

Zhang, G.; E.B. Patuwo, and M.Y. Hu (1998) *Forecasting with Artificial Neural Networks: the State of the Art*; Int. J. Forecasting, No.14: 35-62.

Zheng, Li., etal. (2010) *Forecasting Automobile Petrol Demand in Australia: An Evaluation of Empirical Models*; Transportation Research Part A, No. 44: 16-38.