

پیش‌بینی تقاضای خدمات بانکداری الکترونیک در ایران با استفاده از روش‌های شبکه عصبی مصنوعی و SARIMA*

غلامعلی شرزه‌ای

دانشیار دانشکده اقتصاد دانشگاه تهران، sharzeie@ut.ac.ir

امیر حسین غفاری نژاد**

کارشناس ارشد علوم اقتصادی از دانشگاه مفید، amirhosein.ghafarinejad@gmail.com

تاریخ دریافت: ۹۲/۱/۲۷ تاریخ پذیرش: ۹۲/۴/۱۰

چکیده

عدم مطابقت تقاضا برای خدمات بانکداری الکترونیک با زیرساخت‌های لازم برای پاسخگویی به آن می‌تواند مشکلات فراوانی را برای یک جامعه ایجاد نموده و روند فعالیت‌های اقتصادی در آن جامعه را کند نماید. از این روی، پیش‌بینی تغییرات تقاضا برای این نوع خدمات در بسترسازی برای تأمین تقاضای مربوطه حائز اهمیت است. هدف اصلی این مقاله پیش‌بینی تقاضا برای خدمات بانکداری الکترونیک با استفاده از دو روش شبکه عصبی مصنوعی و مدل خودرگرسیون میانگین متحرک هم‌انباشته فصلی (SARIMA)، مقایسه میان روش‌ها و بررسی تطابق حجم تقاضا با بسترهای ارائه خدمات در ایران می‌باشد. برای این منظور از نمونه‌ای مشتمل بر 88 مشاهده تراکنش‌های صورت گرفته در 6 کانال فعلی شبکه بانکی کشور از تیرماه 1385 الی مهرماه 1392 استفاده گردیده و تقاضا تا انتهای آبان سال 1393 پیش‌بینی شده است. نتایج حاکی از ادامه روند صعودی تراکنش‌ها و برتری نسبی روش شبکه عصبی دارد. بنابراین توجه جدی به ایجاد زیرساخت‌های ارائه خدمات بانکداری الکترونیک ضروری است.

واژه‌های کلیدی: بانکداری الکترونیک، تقاضا، پیش‌بینی، شبکه عصبی مصنوعی.

طبقه‌بندی JEL: G21، D22، C45، Q41.

* این مقاله برگرفته از پایان نامه کارشناسی ارشد امیرحسین غفاری نژاد به راهنمایی آقای دکتر شرزه‌ای است که در بهمن 1390 در دانشگاه مفید دفاع گردید.
** نویسنده مسئول

1- مقدمه

در عصر حاضر استفاده از نظام‌های پرداخت الکترونیک به قدری متداول گشته که با بروز اختلال در سیستم‌های آن و در نتیجه توقف ارائه خدمات بانکداری الکترونیک، اکثر مبادلات روزمره با مشکل مواجه خواهد شد. ارائه این گونه خدمات نیازمند بسترهای مختلف فنی، حقوقی و فرهنگی بوده و متعاقب با گسترش تقاضا، این بسترها نیز باید توسعه یابند. بنابراین آینده نظام بانکداری الکترونیک یک کشور در درجه اول به واکنش و سطح استفاده جامعه از این خدمات و در درجه بعد به تطابق بسترهای مذکور با تقاضای این خدمات بستگی دارد.

طی سال‌های 1385 تا 1391 تقاضای خدمات بانکداری الکترونیک در ایران روند افزایشی داشته است. به طوری که مقدار این متغیر از 55 هزار میلیارد ریال در سال 1385 به حدود 200,2 هزار میلیارد ریال در پایان سال 1391 رسیده است با این وجود، زیرساخت‌های موجود متناسب با حجم تقاضا توسعه نیافته است. به عنوان مثال تعداد دستگاه‌های خودپرداز (ATM)¹ که در هر جامعه‌ای، اولین و مهمترین کانال ارائه خدمات بانکداری الکترونیک محسوب می‌شود بر مبنای استاندارد جهانی، به ازای هر 1000 نفر یک دستگاه است (در برخی کشورهای پیشرفته این رقم یک دستگاه برای هر 600 نفر می‌باشد)، اما در ایران هر دستگاه خودپرداز را حدود 10,000 نفر باید استفاده کنند (محمد همتی و همکاران، 1389: 3). نمود این مسئله را می‌توان در صف‌های طولانی این دستگاه‌ها مشاهده نمود؛ مسلماً این صف‌ها بیانگر حجم بالای نیاز به خدمات و مبادلات الکترونیک در سطح شهرها و روستاها و عدم کفایت تعداد دستگاه‌های پرداخت الکترونیک می‌باشد. حال با توجه به گذشت بیش از یک دهه از آغاز بانکداری الکترونیک در ایران، برای برنامه‌ریزی صحیح آتی و هزینه نمودن منابع لازم در جهت ارتقاء سیستم‌های نوین و همچنین ارائه خدمات مطلوب‌تر، آگاهی از وضعیت تقاضای خدمات بانکداری الکترونیک در آینده بسیار حائز اهمیت می‌باشد. این امر مستلزم پیش‌بینی تقاضای خدمات بانکداری الکترونیک بر مبنای روش‌های مورد تأیید صاحب‌نظران است.

یکی از متداول‌ترین روش‌های پیش‌بینی متغیرها، الگوهای شبکه عصبی مصنوعی (ANN)² است که مدل ساده شده‌ای از سیستم عصبی مرکزی انسان می‌باشند و همانند

¹ Automated Teller Machine

² Artificial Neural Networks

مغز با پردازش روی داده‌های تجربی، قانون نهفته میان داده‌ها را فراگرفته و به ساختار شبکه منتقل می‌کنند. شبکه‌های عصبی مصنوعی دارای قابلیت طراحی انعطاف‌پذیر توابع غیرخطی بوده و در نتیجه می‌توانند هر تابع پیوسته‌ای را با دقت بالایی برآورد کنند؛ در حالی که اکثر مدل‌های سری زمانی خطی این ویژگی را ندارند.

هدف اصلی این مقاله پیش‌بینی تقاضا برای خدمات بانکداری الکترونیک و بررسی تطابق حجم تقاضا با بسترهای ارائه خدمات با استفاده از دو مدل خودرگرسیون میانگین متحرک هم انباشته فصلی (SARIMA)¹ و شبکه عصبی مصنوعی پیش‌خور سه لایه ANN⁸⁻³⁻¹ و مقایسه میان دو مدل می‌باشد. نمونه مورد استفاده مشتمل بر 88 مشاهده از تراکنش‌های صورت گرفته در 6 کانال فعلی شبکه بانکی کشور از تیرماه 1385 الی مهرماه 1392 می‌باشد. دلیل انتخاب این دوره زمانی عمر اندک بانکداری الکترونیک در ایران و کمبود مشاهدات آماری است. با استفاده از نتایج پیش‌بینی‌های کوتاه‌مدت می‌توان زیرساخت‌هایی مانند تعداد دستگاه‌های ارائه خدمات (خودپرداز، پایانه فروش²، پایانه شعب³ و ...) را تعدیل نمود و با پیش‌بینی‌های بلندمدت می‌توان زیرساخت‌های مخابراتی، اینترنتی و یا حتی حقوقی و فرهنگی مرتبط را بهبود بخشید.

در ادامه بعد از پرداختن به ادبیات موضوع و بررسی وضعیت بانکداری الکترونیک در کشور، به معرفی نمونه، تبیین روش تحقیق و نحوه مدلسازی پرداخته می‌شود. سپس انتخاب مدل بهینه و آموزش آن، برآورد مدل SARIMA و در نهایت به بحث و ارزیابی مدل و جمع بندی مطالب پرداخته خواهد شد.

2- مطالعات پیشین

در زمینه پیش‌بینی تقاضای خدمات بانکداری الکترونیک یا پیش‌بینی حجم پول الکترونیک، مطالعات مختلفی در خارج و داخل کشور صورت پذیرفته است. در اکثر آنها از چند روش مختلف پیش‌بینی بهره گرفته شده است. همچنین در برخی از موارد تنها بر یکی از کانال‌های ارائه خدمات بانکداری الکترونیک مانند تلفن‌بانک یا همراه بانک به عنوان متغیر وابسته تمرکز شده است.

¹ Seasonal Autoregressive Moving Integrated Average Model

² POS

³ Pin-Pad

برخی مطالعات برای پیش‌بینی از مدل‌های خودرگرسیون استفاده نموده‌اند. برای مثال، انگل و راسل^۱ (1994) به پیش‌بینی تراکنش‌های مربوط به مبادله بانکی سهام با استفاده از مدل خودرگرسیونی مشروط به زمان (ACP)^۲ و داده‌های 000,50 تراکنش صورت گرفته در طول دوره سه ماهه نوامبر 1990 تا ژانویه 1991 پرداخته‌اند. ماس و همکاران^۳ (2003) بر اساس روش‌های پویای خطی مدل‌های خودرگرسیونی (AR) و خودرگرسیونی میانگین متحرک (ARMA) و نیز روش غیرخطی تکنیک موجکی^۴ اقدام به پیش‌بینی متوسط تعداد تراکنش‌های ماهانه بانکی نموده و بر اساس آماره میانگین درصد خطا (MPE)^۵ پیرامون خطای پیش‌بینی‌های صورت گرفته قضاوت نموده‌اند. مشاهدات مورد استفاده برای متوسط تعداد تراکنش‌های بانکی در این مقاله شامل 51 ماه بوده که از 40 مشاهده اولی برای پیش‌بینی و از بقیه آنها برای سنجش پیش‌بینی بهره گرفته شده است و در مجموع 17 ماه آینده خارج از نمونه را پیش‌بینی کرده‌اند. در نهایت مدل ARMA مبتنی بر برازش روش حداقل مربعات به عنوان بهترین مدل جهت پیش‌بینی مذکور معرفی گردیده است. ایگان و همکاران^۶ (2007) که در مطالعه خود به پیش‌بینی تقاضای همراه بانک در ایالات متحده و در دوره 2007-2012 با استفاده از روش AR پرداخته‌اند. سیموتس و همکاران^۷ (2008) به پیش‌بینی تقاضای روزانه پول از دستگاه‌های ATM با بهره‌گیری از دو روش شبکه‌های عصبی و مدل‌های خودرگرسیونی اقدام نموده و نتیجه گرفته‌اند که ضمن مناسب بودن هر دو روش در پیش‌بینی تقاضای روزانه پول از دستگاه‌های ATM، روش ANN دقیقتر می‌باشد.

برخی دیگر از مطالعات بر مبنای تئوری تقاضا و تعیین عوامل مؤثر بر تقاضای خدمات بانکداری الکترونیک، اقدام به پیش‌بینی این متغیر نموده‌اند. به عنوان نمونه اسنلمن و وسالا^۸ (1999) با استفاده از روش داده‌های تلفیقی^۱ غیرخطی به صورت اثرات ثابت^۲ به

^۱ Engle & Russell.

^۲ Autoregressive Conditional Duration Model

^۳ Maass, Koehler, Kalden, Costa, Parlitz, Merkwirth & Wichard.

^۴ Wavelet Technique

^۵ Mean percentage error = $\frac{\sum |Y_t - \hat{Y}_t|}{n}$

^۶ Egan, Tubin & Vyas

^۷ Rimvydas Simutis, Darius Dilijonas & Lidija Bastina

^۸ Snellman & Vesala

پیش بینی تقاضای پرداخت‌های الکترونیکی بانکی در فنلاند پرداخته‌اند. آنها سهم انواع پرداخت‌های الکترونیکی (مثلاً پرداخت‌ها از طریق POS) از کل پرداخت‌های الکترونیکی را در دوره 1988 تا 1996 برآورد نموده و برای دوره 1997 تا 2006 این مقادیر را پیش‌بینی نموده‌اند. آدام³ (2000) تقاضای حقیقی تراکنش‌های پولی شیلی را با استفاده از روش هم‌انباشتگی جوهانسن و جوسیلیوس⁴ و داده‌های ماهانه دوره 1986-2000 و همچنین مدل تصحیح خطای برداری (VECM)⁵ تخمین زده و پیش‌بینی نموده‌اند. در این مطالعه متغیرهایی از قبیل درآمد حقیقی، نرخ بهره داخلی سپرده‌های کوتاه‌مدت و بردار متغیرهای دامی تعطیلات ملی و حجم پول ذخیره بانک مرکزی به عنوان متغیرهای توضیحی در نظر گرفته شده است. نتایج حاکی از قدرت بالای مدل خودرگرسیون در پیش‌بینی دوره خارج از نمونه متغیر تقاضای حقیقی تراکنش‌های پولی بوده است.

گن و همکاران⁶ (2005) در مطالعه خود به پیش‌بینی انتخاب مشتریان میان بانکداری الکترونیک و غیر الکترونیک در قالب تحقیقی میدانی پرداخته‌اند. متغیرهای مختلفی از قبیل کیفیت خدمات، درک ریسک، عوامل قیمتی، عوامل فردی مؤثر بر انگیزه استفاده مشتریان از خدمات بانکداری الکترونیک، ویژگی‌های محصول و ویژگی‌های شخصی (ویژگی‌های جمعیت شناختی: سن، جنس، نژاد، اشتغال، سواد، درآمد و...) در نظر گرفته شده و مدل با استفاده از 3 روش رگرسیون لاجستیک⁷، شبکه‌های عصبی احتمالی (PNN)⁸ و پیشخور چند لایه (MLFN)⁹ برازش شده است. نتایج نشان می‌دهد که مدل شبکه عصبی احتمالی در پیش‌بینی تقاضای بانکداری الکترونیک از سایر مدل‌ها موفق‌تر می‌باشد. پُل و مُخرَجی¹⁰ (2010) به پیش‌بینی تقاضای پول نقد از دستگاه‌های ATM دو بانک تجاری در هند با استفاده از تراکنش‌های صورت گرفته از جولای تا آگوست سال 2003 و با بکارگیری روش‌های AR پرداخته‌اند. در این مطالعه متغیرهای مستقلی از قبیل محل شعبه یا دستگاه ATM، تعداد حساب‌های جاری، تعداد حساب‌های بازنشستگی، تعداد

¹ Panel Data

² Fixed Effect

³ Adam

⁴ Johansen & Juselius (1995)

⁵ Vector Error Correction Model

⁶ Gan, Clemes, Limsombunchai & Weng.

⁷ logistic regression

⁸ probability neural network

⁹ multi-layer feed-forward neural network

¹⁰ Paul & Mukherjee

حساب‌های حقوق و دستمزد و متغیر دامی تعطیلات به عنوان عوامل مؤثر بر تقاضا در نظر گرفته شده است.

در میان مطالعات داخلی، محققین کمی به پیش‌بینی تقاضای خدمات بانکداری الکترونیک پرداخته‌اند. رسولی نژاد (1391) در مطالعه‌ای جامع به پیش‌بینی رشد بانکداری الکترونیک در ایران پرداخته است. مقطع زمانی مورد استفاده وی 1380-1391 بوده و همانند مطالعه گن و همکاران (2005)، او نیز متغیرهایی از قبیل رشد کارت‌های اعتباری، رشد سرمایه فناوری اطلاعات، رشد بازدیدکنندگان وبسایت‌های بانک‌ها و رشد جمعیت باسواد را به عنوان عوامل مؤثر بر رشد بانکداری الکترونیک در نظر گرفته و با استفاده از روش‌های مختلف شبکه عصبی شامل پیشخور چند لایه، تابع شعاع مدار¹، رگرسیون تعمیم یافته² و مجموعه روش‌های پردازش داده‌ها (GMDH)³ به پیش‌بینی رشد بانکداری الکترونیک پرداخته است. ضرایب همبستگی جزئی هر یک از متغیرها با متغیر وابسته بیش از 80٪ بوده و در نهایت محقق نتیجه می‌گیرد که قدرت پیش‌بینی مدل پیشخور چند لایه از بقیه مدل‌ها بالاتر است. در مطالعه وی کلیت نظام بانکداری الکترونیک یعنی از هر دو جنبه عرضه و تقاضا و عوامل مؤثر بر آنها در نظر گرفته شده است.

تمرکز مقاله حاضر بر جنبه تقاضای خدمات بانکداری الکترونیک بوده که در اقتصاد ایران کمتر به این مسئله توجه شده است. از جهت متغیر وابسته همانند مطالعه ماس و همکاران (2003) بوده با این تفاوت که به جای متوسط تراکنش‌های ماهانه، کل تراکنش‌های ماهانه صورت گرفته از 6 کانال ارائه خدمات بانکی در نظر گرفته شده است. همچنین در امر برآورد با روش شبکه عصبی، همانند مطالعه گن و همکاران (2005) از شبکه پیشخور چند لایه استفاده شده است؛ زیرا پیش‌بینی این مطالعه بر اساس روند گذشته متغیر وابسته بوده و متغیرهای مؤثر در نظر گرفته نمی‌شوند، بنابراین شبکه‌های پیشخور چند لایه کفایت می‌کنند. لازم به ذکر است که برخی از مطالعات حوزه پیش‌بینی متغیرهای اقتصادی، از تبدیل موجکی در مدلسازی شبکه عصبی به منظور افزایش کارایی شبکه استفاده کرده‌اند

¹ Radial basis function

² Generalize Regression Network

³ Group Method of Data Handling

منتها نتایج ارزیابی مدل برای شبکه عصبی با و بدون تبدیل موجکی، تفاوت چندانی نداشته است.^۱

3- وضعیت بانکداری الکترونیک و تقاضا برای آن در ایران

گسترش فناوری اطلاعات در سطح جهان و لزوم تجارت الکترونیک میان ملل مختلف باعث شد تا در اواخر دهه 1360 نیاز به الکترونیکی شدن عملیات بانکی در کشور احساس شود. در سال های 1370 و 1371 اقداماتی در جهت مکانیزه نمودن امور بانکی صورت گرفت، اما هرگز از سیستم‌های جامع نرم افزاری مبتنی بر اینترنت استفاده نگردید و خلأ یک نظام الکترونیکی یکپارچه و منسجم بین بانکی احساس می‌گردید.

طرح جامع خودکار شدن نظام بانکی در سال 1372 با تأکید و اصرار بانک مرکزی بر سیستم بانکی کشور تحمیل گردید، اما نتایج مثبتی به همراه نداشت. به موجب طرح مذکور پردازشگرهای POS در داخل بانک‌ها قرار گرفت و حدود 1/8 میلیون کارت در نظام بانکی کشور صادر و به مشتریان تحویل داده شد تا از دستگاه های POS و ATM جهت رفع امور بانکی خود استفاده نمایند. البته به دلیل عدم پشتیبانی به موقع و صحیح ATMها و همچنین عدم نصب POSها در مراکز فروش، این طرح با استقبال خوب مشتریان مواجه نشد (محمد بیگیان، 1384: 35-36).

از سال 1380 اجرای این طرح بر عهده خود بانک‌ها نهاد شد و شرکت خدمات انفورماتیک ایران، امکانات لازم را برای پیاده‌سازی امور الکترونیکی در اختیار بانک‌ها قرار داد. بکارگیری سیستم یکپارچه شتاب (شبکه تبادل اطلاعات بین بانکی) در سال 1381 گام مؤثری در جهت توسعه بانکداری الکترونیک در کشور بود. با ایجاد شبکه شتاب با هر کارت بانکی می‌توان از POS و ATM بانکی دیگر نیز استفاده نمود.

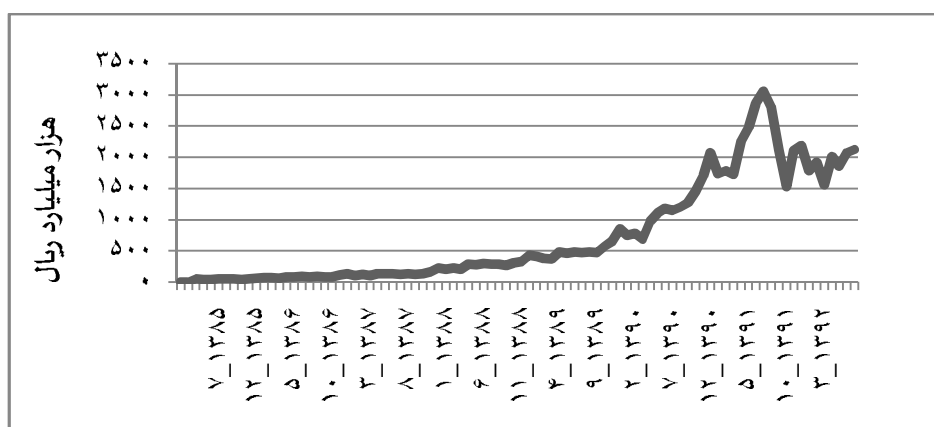
در حال حاضر در ایران تنها 6 کانال برای ارائه خدمات بانکداری الکترونیک وجود دارد که به قرار زیر می باشد.

- 1) دستگاه های خود پرداز (ATM)
- 2) پایانه های فروش (POS)
- 3) پایانه های شعب (Pin-Pad)
- 4) تلفن بانک
- 5) بانکداری تلفن همراه (همراه بانک)

^۱ برای مطالعه بیشتر رجوع شود به: عباسی نژاد و محمدی (۱۳۸۶)؛ صادقی و ذوالفقاری (۱۳۸۹).

۶) بانکداری اینترنتی (اینترنت بانک)

3 کانال نخست، مبتنی بر کارت بوده و برای انجام هر گونه تراکنشی، وجود فیزیکی کارت اجتناب‌ناپذیر است. با استفاده از این کانال‌ها می‌توان خدمات مختلف بانکداری الکترونیک نظیر انتقال وجه، مانده‌گیری، پرداخت قبوض و ... را انجام داد. به نظر می‌رسد که بهترین شاخص برای اندازه‌گیری حجم تقاضای خدمات بانکداری الکترونیک، کل مبلغ تراکنش یافته از 6 کانال فوق در سیستم بانکی کشور باشد. در نمودار (1) روند ماهانه این متغیر از تیر 1385 تا مهر 1392 نشان داده شده است.



نمودار (1): کل مبلغ تراکنش یافته از شبکه بانکی کشور

منبع: اداره نظام‌های پرداخت بانک مرکزی ج.ا.ایران

همان‌طور که ملاحظه می‌شود در مدت مذکور روند صعودی تقاضا و شتاب فوق‌العاده آن از اواخر سال 1389 به بعد به این نمودار حالت نمایی بخشیده است. دلایل مختلفی را می‌توان در بروز این شیب فوق‌العاده عنوان نمود ولی مهمترین آنها، اجرای طرح هدفمند سازی یارانه‌ها از سوی دولت می‌باشد. در سال 1389 برای آغاز طرح مذکور بسیاری از افرادی که تا آن زمان فاقد حساب بانکی دارای کارت بوده‌اند، تقاضای افتتاح حساب نمودند که نتیجه این امر منجر به دو برابر شدن نرخ رشد تقاضای کارت‌ها در این سال نسبت به سال 1388 شده است (غفاری نژاد، 1390: 93-94).

روند تقاضای خدمات بانکداری الکترونیک نشان می‌دهد که در فاصله زمانی آبان 1390 تا بهمن 1391 در روند تقاضا شوک پدید آمده است. این امر را می‌توان در تغییرات نرخ ارز در بازار رسمی و آزاد کشور در دوره 91-1390 دانست. افزایش نرخ ارز باعث گسترش تورم و در پی آن افزایش سرعت گردش پول و حجم تراکنش‌های بانکی شده است. از اوایل سال 1392 روند صعودی تقاضا به حالت قبل از شوک برگشته که این امر نتیجه سیاست‌ها و اقدامات دولت و بانک مرکزی در جهت کنترل نرخ ارز و مهار تورم می‌باشد.

5- روش تحقیق

با توجه به روش‌های به کار گرفته شده در مطالعات تجربی، برای پیش‌بینی روند آتی یک متغیر می‌توان از هر دو روش باکس-جنکینز¹ و شبکه‌های عصبی مصنوعی بهره برد. تمرکز این مقاله نیز بر استفاده از هر دو روش شبکه عصبی و باکس-جنکینز می‌باشد.

همچنین در انجام چنین پیش‌بینی‌هایی که مرتبط با تقاضای جامعه و فناوری‌های نوین می‌باشد، می‌توان جمعیت و نوآوری و سایر متغیرهای مؤثر بر تقاضا را نیز به عنوان متغیرهایی توضیحی در مدل استفاده نمود که در این مطالعه با توجه به اینکه از داده‌های ماهانه متغیر وابسته استفاده شده است، به نظر نمی‌رسد که در مشاهدات ماهانه متغیرهای مؤثر بر تقاضای خدمات بانکداری الکترونیک تغییرات قابل توجهی رخ داده باشد. بنابراین با توجه به دوره پژوهش حاضر، تقاضای خدمات بر اساس روند گذشته آن مورد پیش‌بینی واقع شده و در تجزیه و تحلیل داده‌ها و انجام پیش‌بینی مذکور از بسته نرم افزاری متلب نسخه 2007² و ایویوز³ استفاده شده است.

دوره مدنظر این مطالعه با توجه به محدودیت آمارهای گردآوری شده توسط بانک مرکزی، از تیرماه 1385 الی مهر ماه 1392 (مشاهده 88) انتخاب شده و برای متغیر تقاضای خدمات بانکداری الکترونیک، کل مبلغ تراکنش‌های صورت گرفته از 6 کانال فعلی شبکه بانکی کشور در نظر گرفته شده است. آمارهای مربوطه توسط اداره نظام‌های پرداخت بانک مرکزی گردآوری شده و به درخواست محققین این مقاله، به آنها ارائه شده است.

¹ Box-Jenkins

² Matlab 2007

³ Eviews 8

6- مدلسازی شبکه عصبی

شبکه‌های عصبی مصنوعی قادر به تقریب‌زنی انواع مختلفی از روابط غیرخطی بدون نیاز به وجود یا عدم وجود مانایی در داده‌ها می‌باشند، بنابراین در ابتدا تنها لازم است که نوع شبکه و روش آموزش آن مشخص گردد. با توجه به آنکه شبکه‌های عصبی پیش‌خور با یک لایه پنهان، پرکاربردترین شکل شبکه عصبی برای الگوسازی و پیش‌بینی سری‌های زمانی بوده (ژانگ¹، 2003) و اکثر محققین در مطالعات خود از روش آموزش پس انتشار خطا² بهره گرفته‌اند (قدیمی و مشیری، 1381) در این مطالعه نیز از همین روش استفاده شده است. باید متذکر شد که روش پس انتشار خطا متداول‌ترین روش برای کاهش خطا بوده و در آن، پس از محاسبه خطای پیش‌بینی، وزن‌های سیناپسی³ از آخرین لایه به سوی نخستین لایه به تدریج طوری تغییر می‌کنند که خطای پیش‌بینی کمتر شود. در طراحی مدل‌های شبکه عصبی پس از تشخیص نوع شبکه لازم است تا داده‌ها نرمال سازی شوند تا در بازه [0 و 1] قرار گیرند. این امر به دلیل آن است که در اغلب مسائل پیش‌بینی بهتر است که از تابع فعال‌سازی تانژانت سیگموئیدی⁴ یا هیپربولیکی⁵ در لایه پنهان استفاده شود (ژانگ و همکاران، 1998: 44). این توابع که نقش عمده‌ای در کارکرد شبکه دارند، نمی‌توانند میان مقادیر خیلی بزرگ تفاوت قائل شوند و هر چه ورودی این توابع بیشتر شود، خروجی آنها به سمت 1 یا 0- نزدیک‌تر می‌شود. تابع سیگموئید که در پیش‌بینی‌های سری زمانی عمومی‌تر از تانژانت هیپربولیک می‌باشد، به راحتی میان 1 و 0/8 تفاوت قائل می‌شود اما تشخیص مقادیر 1000 و 500000 برای آن بسیار مشکل بوده و این امر آموزش شبکه را مشکل خواهد ساخت. بنابراین با استفاده از رابطه زیر متغیر مدنظر در فاصله [0 و 1] نرمال شده و در تحلیل‌های شبکه عصبی به کار گرفته می‌شود. (هایکین⁶، 1994)

$$X_n = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

¹ Guoqiang Zhang

² Back Propagation

³ اتصالات میان نرون‌های موجود در هر لایه، وزن‌های سیناپسی می‌باشند. نرون یا گره کوچکترین واحد پردازش اطلاعات است که اساس عملکرد شبکه را تشکیل می‌دهد. هر لایه مجموعه‌ای از نرون‌هاست.

⁴ Sigmoid tangent transfer function

⁵ Hyperbolic

⁶ Simon Haykin

پس از مشخص شدن موارد فوق، برای طراحی مدل شبکه بایستی مراحل زیر طی شود:

6-1- تشخیص توپولوژی یا ساختار شبکه

شبکه‌های عصبی علی رغم تنوع، از ساختار لایه‌ای مشابهی (ورودی، میانی (پنهان) و خروجی) برخوردارند و تنها تفاوت در تعداد لایه‌های میانی آنها می‌باشد. یک شبکه عصبی سه لایه، قادر به شبیه سازی هر گونه معادلات غیرخطی است اما با توجه به نوع مسئله ممکن است نیاز به لایه‌های میانی بیشتری احساس شود. تعداد لایه‌ها از آن دست مسائلی است که معمولاً با روش سعی و خطا به دست می‌آید. باید توجه داشت که با افزایش تعداد لایه‌های شبکه، حجم محاسبات نیز به شدت افزایش یافته و مدت زمان آموزش شبکه طولانی‌تر می‌شود. همچنین افزایش لایه‌ها باعث کاهش تأثیر ورودی‌ها در خروجی به دلیل عبور از لایه‌های متعدد خواهد شد. به همین علت، افزایش تعداد لایه‌ها به بیش از سه لایه مرسوم نمی‌باشد. (هاوارد و همکاران¹، 2007: فصل 2: 11-13)

علاوه بر این، در هر لایه می‌توان از تابع فعال سازی متفاوتی استفاده نمود. همان طور که گفته شد در لایه پنهان بهتر است از تابع تانژانت سیگموئید استفاده شود. همچنین در لایه خروجی با توجه به بسیاری از مطالعات به ویژه مطالعه چاوین و همکاران² (1995) که پشتوانه نظری ارجحیت توابع خطی را در لایه خروجی شبکه‌های پیش خور بررسی کرده و نشان داده‌اند که این توابع مناسب‌تر از سایر توابع هستند، از تابع خطی استفاده می‌شود.

6-2- تعیین تعداد نرون‌های لایه ورودی

در مسائل پیش‌بینی سری زمانی، تعداد نرون‌های لایه ورودی برابر با تعداد مشاهدات تأخیر یافته متغیر اصلی در نظر گرفته می‌شود. محققین بسیاری مانند تانگ و فیشویک³ (1993)، کهزادی و همکاران (1379) تعداد ورودی شبکه را برابر با تعداد متغیر تأخیر یافته فرایند خودرگرسیون (AR) در نظر گرفته‌اند. اما شارددا و پاتیل⁴ (1992)، تانگ و همکاران (1991) دوازده نرون را برای داده‌های ماهانه و چهار نرون را برای داده‌های فصلی به کار گرفته‌اند. در مجموع هیچ قاعده خاصی جهت انتخاب تعداد نرون‌های این لایه وجود نداشته و بهترین روش، سعی و خطا است.

6-3- تعیین حجم نمونه برای بخش آموزش شبکه و بخش پیش‌بینی آن

¹ Howard, Demuth and Mark Beale.

² Yves Chauvin and David E. Rumelhart

³ Zaiyong Tang and Paul A. Fishwick

⁴ Sharda and Patil

از کل مشاهداتی که در چنین مطالعاتی وجود دارند، بخشی در فرایند آموزش شبکه و بخشی برای سنجش میزان عملکرد شبکه مورد استفاده قرار می‌گیرند. عملکرد شبکه با مقایسه میزان پیش‌بینی شده و مقدار هدف سنجیده شده و بازتاب این مقایسه در شاخص -هایی از قبیل میانگین مربع خطا (MSE)¹، ریشه میانگین مربع خطا (RMSE)²، میانگین قدرمطلق درصد خطا (MAPE)³، میانگین قدرمطلق انحراف (MAD)⁴، مجذور ضریب همبستگی (R²)⁵ و آماره U تایل⁶ نمایان می‌شود. معمولاً در هر مطالعه‌ای تخصیص داده‌ها میان بخش آموزش و سنجش به انتخاب محقق بوده و قاعده خاصی ندارد. به طور معمول محققین بین 70 الی 90 درصد از مشاهدات را برای بخش آموزش در نظر می‌گیرند.

6-4- تعیین تعداد نرون‌های لایه میانی و خروجی

در بیشتر موارد از یک نرون در لایه خروجی استفاده می‌شود (اصفهانیان، 1382: 206) زیرا با چند نرون نوعاً نتایج ضعیفی ایجاد می‌شود. پیرامون نرون‌های لایه میانی باید گفت که هیچ قاعده مشخصی برای تعیین تعداد آن وجود نداشته و صرفاً رویکردهای تجربی وجود دارند. برخی از محققین برای تعیین نرون‌های لایه میانی شبکه‌های معمولی دارای یک لایه مخفی، روش‌های جبری معرفی نموده‌اند اما بهترین روش سعی و خطاست (ژانگ و همکاران⁷، 1998). بنابراین پس از تعیین تعداد نرون‌های لایه ورودی، با افزودن هر واحد

$$^1 \text{ Mean Squared Error} = \frac{\sum (\hat{Y}_t - Y_t)^2}{n}$$

$$^2 \text{ Root of Mean Square Error} = \sqrt{MSE}$$

$$^3 \text{ Error Mean Absolute Percentage} = \frac{\sum \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right|}{n}$$

$$^4 \text{ Mean Absolute Deviation} = \text{Mean percentage error} = \frac{\sum |\hat{Y}_t - Y_t|}{n}$$

$$^5 \text{ R Squared} = 1 - \frac{\sum (\hat{Y}_t - Y_t)^2}{\sum \hat{Y}_t^2}$$

$$^6 \text{ Theil Inequality coefficient Bias Proportion} = \sqrt{\frac{\sum (\hat{Y}_t - Y_t)^2}{\frac{n}{\sum (Y_{t-1} - Y_t)^2}}}$$

⁷ G. Zhang, B. Eddy Patuwo and Michael Hu.

نرون در لایه مخفی معیار ارزیابی پیش‌بینی آن محاسبه و با مدل قبلی مقایسه می‌شود. در عین حال باید توجه داشت که تعداد زیاد نرون‌ها و لایه‌ها از قدرت تعمیم شبکه می‌کاهد.

6-5- تعیین پارامترها و عناصر درونی شبکه

برای شروع آموزش شبکه در نرم افزار متلب لازم است تا پارامترها و عناصر درونی از قبیل نرخ یادگیری¹، تعداد دفعات تکرار²، مقدار هدف³ و قاعده یادگیری⁴ مدل مشخص گردند. در حال حاضر تعداد بسیار زیادی قاعده یادگیری برای شبکه‌های عصبی وجود داشته و طبقه‌بندی‌های مختلفی را نیز دارا می‌باشند. در یکی از این طبقه‌بندی‌ها، شبکه‌های عصبی به دو گروه شبکه‌های عصبی تحت نظارت⁵ و بدون نظارت⁶ تقسیم بندی می‌شوند؛ در روش یادگیری بدون نظارت نمونه بدون قضاوت اولیه در اختیار شبکه قرار می‌گیرد اما در روش تحت نظارت نمونه همراه با قضاوت‌های از پیش تعیین شده آموزش داده می‌شود تا در آینده در صورت برخورد شبکه با نمونه‌های جدید با توجه به روالی که آموزش دیده، عمل کند. (اصغری اسکویی، 1381). کاربرد شبکه‌های عصبی در پیش‌بینی‌های اقتصادی بیشتر بر اساس الگوریتم‌های آموزشی تحت نظارت پایه‌گذاری شده است. نوع دیگر طبقه‌بندی بر اساس ساختار شبکه‌ای یا نحوه اتصال نرون‌ها به یکدیگر در داخل شبکه می‌باشد. مقدار هدف، حداقل مقدار میانگین مجذورات خطای تعیین شده (با دیگر معیارهای ارزیابی) توسط محقق می‌باشد که در فرایند آموزش، در صورت رسیدن شبکه به این مقدار آموزش اتمام می‌یابد. تعداد دفعات تکرار، حداکثر تعداد دفعات آموزش شبکه می‌باشد. نرخ یادگیری یکی از پارامترهای مهم است که در سرعت رسیدن شبکه به مقدار هدف مؤثر است. در این پژوهش، از قاعده یادگیری لوبنبرگ- مارکواردت (LM)⁷ استفاده شده زیرا این روش باعث می‌گردد تا نتایج مدل به مراتب سریع‌تر و دقیق‌تر از زمانی باشد که از روش نزول گرادیان⁸ یا دیگر الگوریتم‌های پس انتشار خطا استفاده می‌شود. نرخ یادگیری برابر با 0/001 و مقدار هدف صفر و برای حداکثر تعداد دفعات مجاز برای تکرار عدد 100 انتخاب گردید.

¹ learning rate

² Epochs

³ Goal

⁴ Training Function

⁵ Supervised


⁶ Unsupervised

⁷ Levenberg-Marquardt algorithm

⁸ Gradient Descent

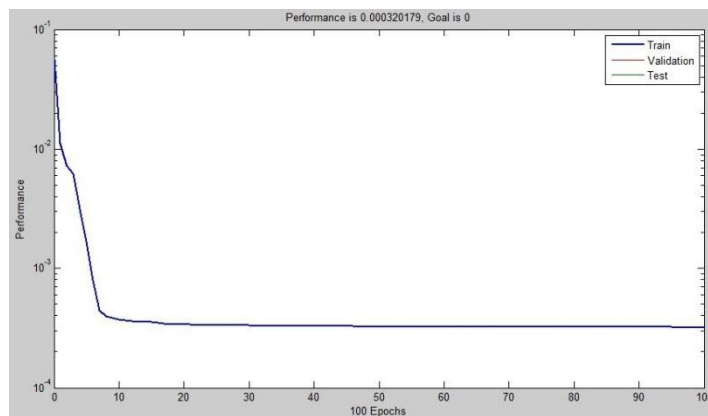
7- انتخاب مدل بهینه و آموزش آن

با توجه به اصول طراحی شبکه‌های عصبی مصنوعی، پس از آموزش شبکه‌های مختلف و آزمون و خطاهای فراوان روی آنها، ساختار ایده‌آل انتخاب گردید. مبنای این انتخاب حداقل بودن میزان میانگین مجذور خطا و تعمیم درست شبکه در پیش‌بینی مقادیر خارج از دوره مدنظر پژوهش می‌باشد. بنابراین ساختار 3 لایه‌ای متشکل از 8 نرون در لایه ورودی، 3 نرون در لایه میانی و 1 نرون در لایه خروجی به عنوان ساختار بهینه انتخاب گردید. ساختار شبکه‌ای ANN^{8-3-1} در شکل (1) قابل مشاهده می‌باشد. همچنین از 88٪ مشاهدات جهت آموزش و از 12٪ مابقی در جهت آزمون شبکه استفاده گردیده است. پس از مشخص شدن ساختار مطلوب شبکه، نتایج آموزش شبکه پس از 100 مرحله تکرار در نمودار (2) ارائه شده است. بر اساس نتایج شبکه پس از 100 مرحله تکرار در جهت کاهش MSE حرکت کرده و در تکرار صدم مقدار $MSE = 0/00032$ را اخذ نموده است.



شکل (1): ساختار شبکه‌ای

منبع: محاسبات محقق



نمودار (2): آموزش شبکه ANN^{8-3-1}

منبع: محاسبات محقق

8- برآورد مدل SARIMA

این روش شامل چهار مرحله شناسایی، تخمین، تشخیص و پیش‌بینی می‌باشد که در مرحله اول مدل‌های آزمایشی با استفاده از معیارهای مربوطه مشخص می‌شوند و پس از آن در مرحله دوم مدل‌های آزمایشی تخمین زده شده و در مرحله سوم با توجه به آزمون‌های تشخیص¹ در صورت لزوم به اصلاح و یا تعدیل مدل تخمین زده شده پرداخته می‌شود. در مرحله آخر نیز پیش‌بینی مقادیر آتی سری زمانی مورد بررسی صورت می‌پذیرد. به طور کلی فرآیندی را ARIMA (p,d,q) گویند که دارای p مرتبه جمله خودرگرسیون، d مرتبه تفاضل گیری و q مرتبه جمله میانگین متحرک باشد. در صورتی که d برابر صفر گردد و یا سری زمانی مورد بررسی در سطح مانا باشد مدل را آرما می‌گویند. مدل عمومی ARMA (p,q) بصورت زیر قابل نمایش است:

$$Y_t = \alpha_0 + \sum_{i=1}^p \beta_i Y_{t-i} + \sum_{j=1}^q \gamma_j \varepsilon_{t-j} + u_t \quad (2)$$

برخی از سری‌های زمانی اقتصادی دارای پدیده فصلی هستند که پس از یک دوره زمانی منظم تکرار می‌شوند که برای مدل‌سازی این سری‌های زمانی می‌توان از مدل‌های ساریما بهره برد. مدل‌های ساریما با نماد SARIMA (p,d,q) (P,D,Q) نمایش داده می‌شوند که به ترتیب، خودرگرسیون و میانگین متحرک مرتبه p و q غیر فصلی و P و Q فصلی می‌باشد. با توجه به نماد فوق‌الذکر مشخص می‌گردد که مدل ساریما از تغییرات درون هر فصل و تغییرات بین فصلی تأثیر می‌پذیرد (جانستون و دیناردو²، 1389). قبل از ورود به روش باکس-جنکینز بایستی از مانایی³ سری زمانی مورد بررسی اطمینان حاصل شود. نتایج آزمون ریشه واحد دیکی فولر تعمیم یافته (ADF)⁴ در جدول (1) ارائه شده است. نتایج حکایت از آن دارد که سری زمانی تقاضای خدمات بانکداری الکترونیک در سطح مانا نبوده و یا به عبارت دیگر دارای ریشه واحد است، لیکن با یک مرحله تفاضل گیری مانا شده و به اصطلاح I(1) است.

¹ Diagnostic tests

² Jack Johnston & John Dinardo.

³ Stationary


⁴ Augmented Dickey-Fuller Unit Root Test

جدول (1): آزمون ریشه واحد دیکی فولر تعمیم یافته

نتیجه	مقدار ADF	مقادیر بحرانی مکینون ¹ در سطوح خطا			مرتبۀ تفاضل	متغیر
		10 درصد	5 درصد	1 درصد		
نامانا	0/3980	-1/6140	-1/9450	-2/5949	سطح	تقاضای خدمات
مانا	-8/8795	-1/6142	-1/9446	-2/5921	اول	بانکداری الکترونیک

منبع: یافته‌های محقق

حال با توجه به ماهانه بودن داده‌ها و برای حصول اطمینان از عدم وجود ریشه واحد فصلی در سری زمانی مورد بررسی می‌توان از نمودار همبسته نگار² مربوطه استفاده نمود، با توجه به نمودار همبسته نگار (نمودار 3) مشخص می‌گردد که سری زمانی مذکور دارای ریشه واحد فصلی 3 ماهه نیز است. از این رو برای پیش‌بینی از تفاضل مرتبه اول و سوم (فصلی) سری زمانی استفاده خواهد گردید.



نمودار (3): همبسته نگار تفاضل مرتبه اول تقاضای خدمات بانکداری الکترونیک

منبع: محاسبات محقق

در گام بعدی با توجه به تفاضل‌گیری فصلی برای شناسایی مدل‌های آزمایشی و تعیین مرتبه AR، SAR، MA و SMA از نمودار همبسته نگار سری زمانی استفاده می‌شود که پس از شناسایی مراتب AR، SAR، MA و SMA مدل‌های ممکن برآورد خواهند شد.

¹ Mackinnon (1996)² Correlogram

استناد به آماره آکائیک^۱ بهترین مدل شامل خودرگرسیون مرتبه اول، خودرگرسیون فصلی مرتبه سوم، میانگین متحرک مرتبه اول و میانگین متحرک فصلی مرتبه سوم است. مدل برآورد شده در جدول (۲) ارائه شده است.

جدول (۲) نتایج برآورد مدل SARIMA

ریشه های معکوس ^۲ جملات MA و AR	ارزش احتمال	آماره t	ضریب	نام متغیر
	0/0000	4/3618	42/7366	C
	0/0000	8/8313	0/8988	AR(1)
	0/0887	1/7252	0/4750	SAR(1)
	0/0000	-7/997	-0/9380	MA(1)
	0/0012	-3/363	-0/8420	SMA(1)
	(0/0118) 3/4697			F
	0/7597			R ²
	1/9454			D.W
	(0/2252) 1/4967			F رمزی ^۳
	(0/9657) 0/0348			F برآش - گادفری ^۴

منبع: محاسبات محقق

همانطور که ملاحظه می‌شود، در مدل برآورد شده تمامی ضرایب در سطوح خطای 1، 5 و 10 درصد معنادار بوده و آماره‌های دوربین واتسن (D.W) و F برآش - گادفری حاکی از عدم وجود خودهمبستگی در مرتبه اول و مراتب بالاتر بوده و F رمزی تصریح درست مدل را نشان می‌دهد. F مدل حاکی از معناداری کل رگرسیون برآورد شده داشته و میزان R² نیز مبین آن است که 75 درصد از تغییرات تقاضای خدمات بانکداری الکترونیک توسط متغیرهای توضیحی ارائه شده در جدول توضیح داده می‌شود. برای بررسی پایداری مدل تخمین زده شده می‌بایست ریشه‌های سیستم ساریما بررسی شود که برای این منظور

¹ Akaike info criterion

² Inverse Roots

³ Ramsey Reset test

⁴ Breusch-Godfrey

نمودار مقادیر ریشه‌های معکوس جملات MA و AR محاسبه شده و پایداری مدل ساریما را تأیید می‌نماید؛ بنابراین می‌توان نتیجه گرفت که الگوی برآورد شده، الگوی مناسبی بوده و می‌توان با استفاده از این مدل به پیش‌بینی مقادیر متغیر مدنظر برای دوره‌های آتی مبادرت ورزید.

9- ارزیابی مدل

در ارزیابی مدل آموزش یافته ANN⁸⁻³⁻¹، شاخص‌های مندرج در جدول (3) در میان دیگر ساختارها مقادیر بهتری را ارائه داده‌اند. در واقع این مدل دارای کمترین میزان MSE، RMSE، MAPE، MAD و آماره U تایل بوده و بیشترین میزان R² را دارا می‌باشد. همچنین مقادیر آماره‌های مذکور برای مدل SARIMA برآزش یافته به منظور مقایسه نتایج دو مدل در جدول (3) ارائه گردیده است.

جدول (3): معیارهای ارزیابی کارایی مدل

MSE	RMSE	MAPE	MAD	U تایل	R ²	معیارها مدل‌ها
0/00032	0/01789	0/13113	0/01012	0/2833	0/9994	مدل ANN
30698/09	175/2087	0/18399	107/6511	0/90807	0/7597	مدل SARIMA

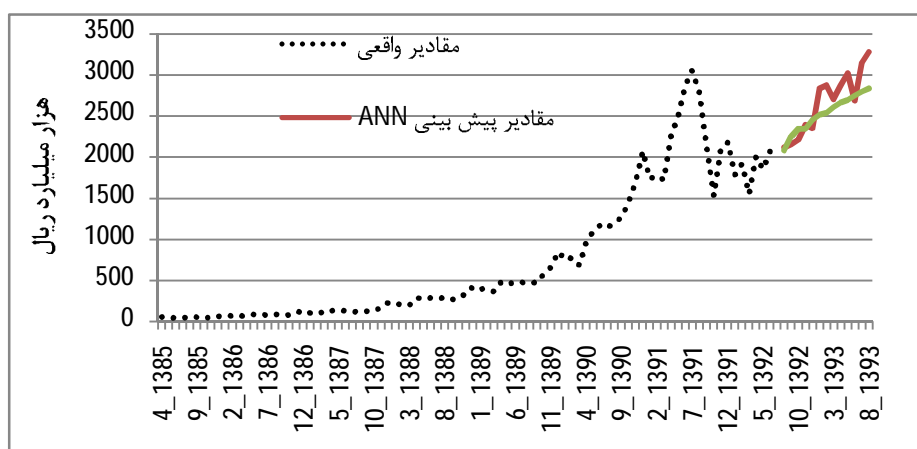
منبع: محاسبات محقق

همانطور که ملاحظه می‌شود، بر اساس تمامی شاخص‌های مندرج در جدول (3) مدل شبکه عصبی آموزش یافته در مقایسه با روش اقتصاد سنجی SARIMA قابلیت اتکای بالاتری داشته و می‌توان با استفاده از آن پیش‌بینی مطمئن‌تری صورت داد.

10- پیش‌بینی و بحث

پس از احراز قابلیت اتکای مدل‌ها، به منظور پیش‌بینی تقاضای خدمات بانکداری الکترونیک از آبان 1392 تا آبان 1393 در مدل ANN از الگوریتم شبیه‌سازی¹ در نرم افزار متلب استفاده شده است. مقادیر پیش‌بینی شده دوره خارج از نمونه که شامل 13 ماه می‌باشد، بر اساس هر دو روش در نمودار (4) ارائه شده است.

¹ Simulation




نمودار (4): روند واقعی و پیش‌بینی شده کل مبلغ تراکنش یافته از شبکه بانکی کشور

منبع: بانک مرکزی و محاسبات محقق

همان‌طور که در نمودار (4) ملاحظه می‌شود بر اساس هر دو روش پیش‌بینی انتظار می‌رود تقاضای خدمات بانکداری الکترونیک روند صعودی خود را همچنان طی نموده و نتایج روش شبکه عصبی نشان می‌دهد که با شروع سال 1393 این تقاضا از مرز 3000 هزار میلیارد ریال خواهد گذشت.

تداوم روند صعودی تقاضا در آینده که مسئله‌ای دور از انتظار هم نمی‌باشد، مسئولین شبکه ارائه خدمات الکترونیکی بانکی را در ارائه خدمات با مشکل روبرو خواهد ساخت. زیرا همان‌طور که گفته شد، میزان زیرساخت‌های مختلف ارائه خدمات بانکداری الکترونیک در کشور مطلوب نمی‌باشد. به عنوان تمرکز تنها روی زیرساخت‌های فنی، مقایسه‌ای میان نرخ رشد تقاضای خدمات با نرخ رشد تعداد دستگاه‌های ارائه خدمات (ATM، POS، Pin-Pad) که هر دو دارای واحد درصد بوده و قابل مقایسه می‌باشند صورت گرفته است. نتایج این مقایسه که در نمودار (5) ارائه شده نشان می‌دهد که در فاصله سال‌های 91-1386¹ همواره همواره نرخ رشد تعداد دستگاه‌ها در هر سال به استثنای سال 1387، پایین‌تر از نرخ رشد تقاضای خدمات بوده است.

¹ انتخاب این بازه زمانی به دلیل محدودیت دسترسی به داده‌ها بوده است.



نمودار(5): روند نرخ رشد تقاضای خدمات و نرخ رشد تعداد دستگاه‌های ارائه خدمات

منبع: محاسبات محقق

روند نرخ رشد دستگاه‌ها نشان می‌دهد که پس از سال 1387 همواره کمتر از 0/5 رشد تقاضای خدمات، تعداد دستگاه‌ها رشد یافته به طوریکه در سال‌های 1390 و 1391 این مقدار به ترتیب به کمتر از یک سوم و یک چهارم رشد تقاضا رسیده است. نکته دیگری که در مورد دستگاه‌های ارائه خدمات وجود دارد این است که تعدادی از آنها که عمدتاً مربوط به بانک‌ها و مؤسسات تازه تأسیس می‌باشند، به سیستم یکپارچه شتاب متصل نیستند و تنها از کارت بانکی همان بانک یا مؤسسه می‌توان روی آن دستگاه استفاده نمود. در مجموع انتظار می‌رود که در آینده حجم تقاضا روند رو به رشد خود را طی کند زیرا روز به روز وضعیت آگاهی جامعه نسبت به استفاده از این گونه خدمات گسترش یافته و جمعیت شاغل جوانتر نیز وارد بازار کار می‌شوند، آگاهی و سطح سواد آنها نسبت به بهره‌گیری از چنین خدمات نوینی قطعاً بالاتر از جمعیت کهنسال خواهد بود. از طرفی با گذشت زمان بانک‌ها و مؤسسات مالی جدیدتری وارد سیستم بانکی کشور شده و با پیوستن به شبکه شتاب به بهبود شرایط عرضه این خدمات و در نتیجه افزایش تقاضای آنها خواهند شد.

11- نتیجه گیری

این مطالعه با هدف تبیین وضعیت اخیر و آینده تقاضای خدمات بانکداری الکترونیک از طریق انجام پیش‌بینی مبتنی بر دو روش شبکه‌های عصبی مصنوعی و روش اقتصادسنجی خودرگرسیون میانگین متحرک هم‌انباشته فصلی صورت پذیرفت و نتایج حاکی از آن بود که طبق هر دو روش، تقاضای خدمات بانکداری الکترونیک روند صعودی خود را همچنان طی نموده و بر اساس روش شبکه عصبی با شروع سال 1393 از مرز 3000 هزار میلیارد ریال بگذرد. همچنین طبق شاخص‌های مختلف ارزیابی مدل‌ها، روش شبکه عصبی قابلیت اتکای بالاتری داشت. همان‌طور که مطرح شد یکی از مهمترین دلایل افزایش فوق‌العاده این تقاضا اجرای قانون هدفمندسازی یارانه‌ها در سال 1389 بوده است. دولت ایران از آذرماه سال 1389 هر دو ماه یکبار یارانه نقدی را به حساب سرپرست هر خانوار ایرانی واریز کرده و این امر موجب افزایش حجم تراکنش‌های بانکی به ویژه از طریق دریافت یارانه نقدی از طریق دستگاه‌های ATM شده است. از طرف دیگر با توجه به عقائد اکثر اقتصاددانان به ویژه طرفداران نظریه پولی تورم، تزریق پول در اقتصاد منجر به بروز تورم خواهد شد. بالا رفتن نرخ تورم در یک جامعه در درجه اول باعث کاهش ارزش پول در نظر افراد می‌گردد و در درجه دوم، انتظارات تورمی نسبت به آینده ایجاد خواهد کرد. مجموعه دو نیروی فوق‌ترتیب رفتار جامعه منجر شده و مردم کالا را به پول ترجیح می‌دهند، در چنین شرایطی افزایش تقاضای کالاها و خدمات مختلف را شاهد خواهیم بود. افزایش تقاضای کالاها به گسترش سرعت گردش پول و در نهایت حجم تراکنش‌های بانکی خواهد انجامید.

همچنین در فاصله سال‌های 91-1390 تغییراتی در جهت افزایش در نرخ ارز در بازار رسمی و آزاد کشور رخ داده و با توجه به آنکه نرخ ارز جزء قیمت‌های کلیدی در هر اقتصادی محسوب شده و تغییر آن بر تمامی بخش‌ها و پیکره جامعه تأثیرگذار می‌باشد؛ این امر به گسترش تورم و در نهایت تقاضای خدمات بانکداری الکترونیک منجر شده است. در مجموع بحث هدفمندسازی یارانه‌ها باعث گردیده که در هر خانواده ایرانی، حداقل یک نفر ولو فاقد سواد دارای حساب بانکی دارای کارت شده و امور جاری خود و خانواده‌اش را از طریق خدمات بانکداری الکترونیک مرتفع سازد. بنابراین در سطح جامعه فعلی نسبت به قبل از اجرای طرح مذکور، افزایش آگاهی پیرامون بانکداری الکترونیک حاصل شده و نیاز

به انجام تراکنش‌های بانکی به مسئله‌ای ضروری در زندگی روزمره افراد تبدیل شده است؛ همگی این موارد حالت صعوی به خود گرفته اند. با تداوم روند صعودی تقاضای خدمات زیرساخت‌های ارائه خدمات آن نیز باید توسعه یابد، اما در طی سال‌های گذشته مسئولین نظام بانکی توجه کافی در این زمینه نداشته‌اند. به منظور بررسی تناسب تقاضای خدمات بانکداری الکترونیک با زیرساخت‌های ارائه خدمات، نرخ رشد تقاضای خدمات بانکداری الکترونیک با نرخ رشد تعداد دستگاه‌های ارائه خدمات آن مقایسه شده و نتایج حکایت از پایین بودن نرخ رشد تعداد دستگاه‌ها در برابر تقاضا در طی سال‌های ۹۱۰-۱۳۸۶ داشت. دلیل این امر را می‌توان در پشتیبانی کمتر از حد مطلوب مسئولین و عدم توجه به افزایش تعداد آنها مطابق با حجم تقاضای مربوطه دانست.

12- پیشنهادها

با توجه به سهم به سزای تورم در افزایش تقاضای خدمات بانکداری الکترونیک و انتظار عدم حل مشکل تورم به طور کامل در کوتاه مدت، لازم است تا حداقل در این بعد زمانی به بسترهای ارائه خدمات توجه کافی شود. البته در این نوشته تمرکز اصلی بر زیرساخت‌های فنی خردی مانند دستگاه‌ها بود، مسلماً با تداوم روند صعودی تقاضا و عدم توسعه زیرساخت‌های مخابراتی، فرهنگی و حقوقی، عدم سازگاری فوق بیشتر نمود می‌یابد. در کوتاه مدت بایستی به توسعه کمی و کیفی دستگاه‌های ارائه خدمات (ATM، POS، Pin- Pad و ...) توجه کافی شده و کنترلی با تناوب زمانی کوتاه‌تر روی آنها صورت پذیرد. همچنین بانک‌ها و مؤسسات تازه تأسیس در سریع‌ترین زمان ممکن اقدامات لازم در جهت پیوستن به شبکه شتاب را انجام دهند.

با انجام پیش‌بینی‌های بلندمدت می‌توان در زیر ساخت‌های کلانی مانند سیستم‌های مخابراتی و اینترنتی بهبود بخشید و نیز توسعه بسترهای حقوقی و فرهنگی مرتبط را اعمال نمود. پیشنهاد می‌شود که در تحقیقات آتی با توجه به بالا رفتن سابقه بانکداری الکترونیک در کشور و گسترش داده‌ها پیرامون آن در کنار افزایش عمر قانون هدمندسازی یارانه‌ها، تأثیرات عواملی نظیر نرخ تورم، نوسانات نرخ ارز و قانون هدمندسازی یارانه‌ها بر تقاضای خدمات بانکداری الکترونیک با استفاده از توابع عکس العمل آنی (IRF)¹ بررسی گردد.

¹ Impulse Response Function

فهرست منابع

۱. اصغری اسکویی، محمد رضا. (1381). کاربرد شبکه‌های عصبی در پیش‌بینی سری زمانی، فصلنامه پژوهش‌های اقتصادی ایران، ش 12: 69-96.
 ۲. اصفهانیان، مجید. (1382). ارائه یک مدل شبکه عصبی جهت پیش‌بینی قیمت نفت خام، پایان نامه کارشناسی ارشد، بخش مهندسی صنایع، دانشگاه تربیت مدرس.
 ۳. جانستون، جک و جان دیناردو (1389). روش‌های اقتصاد سنجی، ترجمه فریدون اهرابی و علی اکبر خسروی نژاد، انتشارات نور علم، چاپ چهارم، جلد اول.
 ۴. رسولی نژاد، احسان. (1390). پیش‌بینی رشد بانکداری الکترونیکی در ایران از طریق شبکه عصبی مصنوعی، اولین همایش بین‌المللی بانکداری الکترونیک و نظام‌های پرداخت، پژوهشکده پولی و بانکی بانک مرکزی جمهوری اسلامی ایران.
 ۵. صادقی، حسین و مهدی ذوالفقاری. (1389). پیش‌بینی کوتاه مدت تقاضای برق کشور با استفاده از شبکه‌های عصبی و تبدیل موجک، بررسی‌های اقتصادی، 7(2): 27-56.
 ۶. عباسی نژاد، حسین و احمد محمدی. (1386). پیش‌بینی نرخ ارز با استفاده از شبکه‌های عصبی و تبدیل موجک، فصلنامه نامه مفید، ش 60: 19-42.
 ۷. عباسی نژاد، حسین و مینا مهرنوش. (1388). بانکداری الکترونیکی، انتشارات سمت، چاپ دوم.
 ۸. غفاری نژاد، امیر حسین. (1390). برآورد عوامل مؤثر بر تقاضای خدمات بانکداری الکترونیک در کشور، پایان نامه کارشناسی ارشد، گروه اقتصاد دانشگاه مفید.
 ۹. قدیمی، محمد رضا و سعید مشیری. (1381). مدلسازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی (ANN)، فصلنامه پژوهش‌های اقتصادی ایران، ش 12: 97-125.
 ۱۰. محمد بیگیان، عبدالله. (1384). مطالعه عوامل مؤثر بر استفاده بهینه از ابزارهای بانکداری الکترونیک (ATM و POS) (مطالعه موردی بانک ملت - تهران)، پایان نامه کارشناسی ارشد، دانشکده اقتصاد و مدیریت واحد علوم و تحقیقات تهران.
 11. همتی، محمد و مهسا شاه حسینی و مجتبی جاوید نیا. (1389). شناسایی و اولویت بندی عوامل مؤثر بر جذب مشتری از طریق دستگاه‌های ATM، دومین کنفرانس بازاریابی خدمات مالی، مرکز بازاریابی خدمات مالی.
1. Adam, Christopher. (2000). The Transactions Demand for Money in Chile, Research Department of the Central Bank of Chile.

2. Chauvin, Y. and Rumelhart D.E. (1995). Backpropagation: Theory architectures, and applications, Hillsdale, NJ: Erlbaum.
3. Egan, Bob and George Tubin and Charul Vyas. (2007). US Mobile Banking Forecast: 2007-2012, www.TowerGroup.com.
4. Engle, Robert F. and Jeffrey R. Russell. (1994). Forecasting Transactions Rates: The Autoregressive Conditional Duration Model, Working Papers, National Bureau of Economic Research, Cambridge.
5. Gan, Christopher and Mike Clemes and Visit Limsombunchai and Amy Weng. (2005), Consumer Choice Prediction: Artificial Neural Networks versus Logistic Model, Commerce Division, Lincoln University Canterbury, No. 104.
6. Haykin, Simon S. (1994). Neural Networks: A Comprehensive Foundation, Macmillan College Publishing.
7. Howard, Demuth and Mark Beale. (2007). Neural Network Toolbox User's Guide, www.mathworks.com.
8. Maass, Peter and Torsten Koehler and Jan Kalden and Roza Costa and Ulrich Parlitz and Christian Merkwirth and Jörg Wichard. (2003). Mathematical methods for forecasting bank transaction data, Zentrum für Technomathematik.
9. Paul, Justin and Anirban Mukherjee. (2010). ATMs and Cash Demand Forecasting: A Study of Two Commercial Banks, Journal of Regional Development, vol.2, no.2, pp: 653-671.
10. Sharda, R. and R.B Patil. (1992). Connectionist approach to time series prediction: An empirical test, Journal of Intelligent Manufacturing 3, pp: 317-323.
11. Simutis, Rimvydas and Darius Dilijonas and Lidija Bastina. (2008). Cash Demand Forecasting for ATM Using Neural Networks and Support Vector Regression Algorithms, 20th EURO Mini Conference: Continuous Optimization and Knowledge-Based Technologies, Vilnius, Lithuania, pp: 416-421.
12. Snellman, Jussi and Jukka Vesala. (1999). Forecasting the Electronification of Payments with Learning Curves: The Case of Finland, Discussion Papers, Bank of Finland, Research Department.
13. Tang, Zaiyong and and Fishwick Paul A. (1993), Feedforward Neural Nets as Models for Time Series Forecasting, Journal on Computing, vol.5, no.4, pp:374-385.
14. Zhang, G. and B. Eddy Patuwo and Michael Hu. (1998). Forecasting with artificial neural network: the state of art, International Journal of Forecasting, vol.14, pp: 35-62.
15. Zhang, Peter .G. (2003). Time series forecasting using a hybrid ARIMA and neural network model, Neuro Computing, vol.50, pp: 159-175