

فصلنامه سیاست‌های راهبردی و کلان/سال دوم، شماره هشتم، زمستان ۱۳۹۴/صفحات ۷۶-۵۹

پیش‌بینی نقدینگی موردنیاز دستگاه‌های خودپرداز با استفاده از مدل خطی (ARIMA) و غیرخطی (شبکه‌های عصبی)

ابراهیم عباسی^۱، فاطمه رستگاریانیا^۲، فهیمه ابراهیمی^۳

تاریخ پذیرش: ۱۳۹۳/۸/۱۷

تاریخ دریافت: ۱۳۹۳/۱۲/۲۰

چکیده

هدف این مطالعه پیش‌بینی نقدینگی مورد نیاز دستگاه‌های خودپرداز با استفاده از دو مدل خطی و غیرخطی است. تامین منابع مالی در دستگاه‌های خودپرداز، از این نظر اهمیت دارد که لازمه فعال نگه‌داشتن خودپرداز در ارائه وجه نقد به متقاضیان و تامین اسکناس در دستگاه است. نتایج چنین تحلیل‌هایی این امکان را ارائه می‌دهد که بتوان پیش‌بینی لازم برای تامین منابع مالی خودپرداز را بصورت هوشمند انجام داد و آن را در ساعات اوج تقاضا فعال نگه داشت. نمونه آماری پژوهش شامل ۷ دستگاه خودپرداز بانک مهر اقتصاد خراسان رضوی طی سال‌های ۱۳۸۶-۱۳۸۹ بوده است. در این پژوهش تعیین میزان برداشت وجه نقد از دستگاه خودپرداز با استفاده از روش غیرخطی شبکه‌های عصبی مصنوعی با ساختار پروسپترون چند لایه و الگوریتم پس‌انتشار خطا و روش خطی آریما بررسی شده است تا مدل بهینه انتخاب شود. تقاضای برداشت وجه نقد از تاریخ ۱۳۸۶/۴ تا ۱۳۸۹/۷ (۴۰ ماه) به عنوان داده‌های آموزش و از داده‌های ۱۳۸۹/۸ تا پایان ۱۳۸۹/۱۲ به عنوان داده‌های آزمایشی در نظر گرفته شده است. نتایج به دست آمده نشان‌دهنده برتری مدل شبکه‌های عصبی مصنوعی نسبت به مدل آریما در پیش‌بینی وجه نقد مورد نیاز دستگاه خودپرداز بانک مهر اقتصاد است.

طبقه‌بندی JEL: C53, E37, Q30

واژگان کلیدی: شبکه‌های عصبی، آریما، پیش‌بینی، وجه نقد، دستگاه خودپرداز، بانک مهر اقتصاد.

۱. دانشیار، عضو هیئت علمی دانشگاه الزهرا (نویسنده مسئول) Email: abbasiebrahim2000@yahoo.com

۲. کارشناس ارشد حسابداری، مدرس موسسه آموزش عالی ساعی (غیرانتفاعی-غیردولتی)

Email: frastegarnia@yahoo.com

۳. کارشناس ارشد مدیریت دولتی - مالی، دانشگاه آزاد علی آباد کتول

Email: Fahimehebrahimi@yahoo.com

مقدمه

دستگاه‌های خودپرداز (ATM) طراحی شده‌اند به‌عنوان وسیله‌های ارتباطی که برای مشتریان موسسات مالی یک راه معامله مالی در یک مکان عمومی بدون نیاز به یک کارمند را مهیا می‌کنند. براساس تخمین‌های گسترش داده شده توسط شرکت صنعتی دستگاه‌های خودپرداز تعداد تمامی دستگاه‌های خودپرداز در سال ۲۰۰۷ بیشتر از ۱/۶ میلیون بوده است. هر قدر شبکه‌های دستگاه‌های خودپرداز گسترش می‌یابد، نظارت درست، بازنگری و مدیریت نقدینگی شبکه‌های دستگاه‌های خودپرداز بسیار مهم است (سنلمان ۲ و همکارش، ۲۰۰۶). عنصر بسیار مهم در گسترش سیستم مدیریت شبکه دستگاه‌های خودپرداز موثر بازنگری روزانه نقدینگی صرف‌نظر از دستگاه‌های خودپرداز و کشف رفتار پیش‌بینی نشده دستگاه‌های خودپرداز ویژه است. بازنگری شبکه دستگاه خودپرداز باید بر مبنای نقدینگی تاریخی روزانه صرف‌نظر از داده وجود آمده باشد. رفتار پیش‌بینی نشده یک دستگاه خودپرداز به دلایل مختلف می‌تواند ضروری باشد. این دلایل می‌توانند با تعدادی موانع در حال رشد در اطراف دستگاه خودپرداز، مشکلات عملیاتی دستگاه‌های خودپرداز، یا عملکردهای غیرقانونی مشتریان همراه باشد. یادآوری این نکته مهم است که برای تشخیص رفتار پیش‌بینی نشده یک دستگاه خودپرداز ویژه مقایسه رفتار دستگاه خودپرداز با رفتار دستگاه‌های خودپرداز مشابه در همسایگی ضروریست. اگر به چند دلیل (وضعیت آب و هوایی، اتفاقات در ناحیه و...) مشکلات متداولی برای همه‌ی دستگاه‌های خودپرداز در همسایگی وجود آمده باشد، بنابراین رفتار تغییر داده شده دستگاه خودپرداز ویژه نباید به‌عنوان پیش‌بینی نشده تفسیر شده باشد. برای موسسات بانکی تشخیص رفتار پیش‌بینی نشده یک دستگاه خودپرداز با سرعت مشابه و همچنین عکس‌العمل به موقع دستگاه خودپرداز برای حل این مشکلات تعیین‌کننده و مهم است. بدلیل اندازه شبکه‌های دستگاه‌های خودپرداز (تعدادی از شبکه‌های دستگاه‌های خودپرداز اصلی موسسات خدماتی با دستگاه‌های خودپرداز بیشتر از ۱۰۰۰ عدد در شبکه) عملیات انسانی نمی‌تواند عملکرد همه‌ی دستگاه‌های خودپرداز را بطور موثر بازنگری کند. بنابراین شیوه‌های اتوماتیکی برای کشف رفتار پیش‌بینی نشده دستگاه‌های خودپرداز باید بکار گرفته شود (سیموتیس ۳ و همکارانش، ۲۰۰۸).

تامین منابع مالی در دستگاه‌های خودپرداز، از این نظر اهمیت دارد که لازمه فعال نگه داشتن خودپرداز در ارائه وجه نقد به متقاضیان و تامین اسکناس در دستگاه است. زیرا در صورت خالی بودن کاست‌های آن، ارائه وجه نقد عملی غیرممکن است. نتایج چنین تحلیل‌هایی این امکان را ارائه می‌دهد که بتوان پیش‌بینی لازم برای تامین منابع مالی خودپرداز را بصورت هوشمند انجام داده و آن را در ساعات اوج تقاضا فعال نگه داشت.

هدف این پژوهش پیش‌بینی نقدینگی مورد نیاز دستگاه‌های خودپرداز با استفاده از مدل خطی و غیرخطی است که این پیش‌بینی در هیچ پژوهش دیگری تا به امروز در ایران مورد مطالعه قرار نگرفته است.

¹. Automatic teller machines.

². Snellman et al., 2006.

³. Simutis et al., 2008.

ساختار مقاله در ادامه بدین شکل است: در قسمت بعد مطالعات انجام شده بررسی می‌شود. در قسمت سوم مبانی نظری ارائه می‌گردد. در قسمت چهارم ساختار الگو مورد بحث قرار می‌گیرد. در قسمت پنجم برآورد نتایج و تجزیه و تحلیل و در نهایت پیشنهادات سیاست‌گذاری ارائه می‌شود.

۱. مطالعات انجام شده

المرا و همکارش (۱۹۹۸) برای پیش‌بینی توانایی پرداخت وام‌ها از مدل شبکه‌ی عصبی چند لایه پروسپترون استفاده نموده‌اند. نتایج این پژوهش حاکی از این بود که قدرت پیش‌بینی مدل پروسپترون بیشتر از مدل‌های نمره‌دهی اعتباری بوده است.

هارنگ و همکارش (۲۰۰۱) یک مدل ساده شبکه‌های عصبی مصنوعی برای مدل‌سازی آریما^۳ برای سری‌های زمانی استفاده کردند. آنها دریافتند هنگامی که از داده‌های پیچیده و غیرخطی استفاده کردند، مدل شبکه‌های عصبی قادر به مدل‌سازی مناسب‌تری برای داده‌ها بوده و این در حالی است که مدل‌های خطی آریما چنین قابلیت‌هایی برای داده‌های غیرخطی ندارد.

سیموتیس و همکارانش (۲۰۰۸) پیش‌بینی تقاضای وجه نقد با کاربرد شبکه عصبی و نظارت الگوریتم را مورد بررسی قرار دادند. آنها دریافتند درصد میانگین قدر مطلق خطا برای شبکه‌ی عصبی مصنوعی شبیه‌سازی شده نسبت به مدل SVR با اعتبار ۰.۴۱٪، ۰.۷۶٪ کمتر است.

موسوی (۱۳۸۴) در پژوهشی به طراحی مدل مناسب پیش‌بینی نقدینگی مورد نیاز موسسات و نهادهای مالی با استفاده از شبکه‌های عصبی پرداخت. آن به منظور پیش‌بینی مولفه‌های نقدینگی از تکنیک شبکه عصبی پروسپترون چند لایه با الگوریتم پس انتشار خطا استفاده نمود و توانست با آموزش شبکه از داده‌های ۴ ماه اول سال استفاده کرده و به منظور آزمون شبکه پیش‌بینی نقدینگی مورد نیاز را برای ماه هشتم سال انجام دهد.

فرجام‌نیا و همکارانش (۱۳۸۶) در پژوهشی به پیش‌بینی قیمت نفت با دو روش آریما و شبکه‌های عصبی با ۵ وقفه در دوره‌ی آوریل ۱۹۸۳ تا ژوئن ۲۰۰۵ پرداختند. همچنین به منظور تشخیص سهم مشارکت هر پارامتر ورودی، در این مدل از تجزیه و تحلیل حساسیت استفاده کردند. نتایج آنها نشان از برتری غیرقابل مقایسه مدل شبکه‌های عصبی مصنوعی نسبت به مدل آریما در پیش‌بینی قیمت روزانه نفت بود. تهرانی و همکارش (۱۳۸۵) در طراحی و تبیین مدل ریسک اعتباری در نظام بانکی کشور با استفاده از داده‌های اعتباری ۳۱۶ مشتری حقوقی بانک‌های کشور و با استفاده از مدل‌های احتمال خطی، لجستیک و شبکه‌های عصبی مصنوعی اقدام به طراحی و آزمون کارایی مدل ریسک اعتباری نموده است. نتایج حاکی از این بود که ارتباط بین متغیرها در مدل پیش‌بینی ریسک اعتباری به صورت خطی نبوده و تابع-

^۱. Elmer et al., 1998.

^۲. Hwang et al., 2001.

^۳. ARIMA.

های نمای و سیگموئید مناسب‌ترین مدل‌های پیش‌بینی ریسک اعتباری است و بیشترین کارایی برای پیش‌بینی ریسک اعتباری به ترتیب مربوط به شبکه‌های عصبی مصنوعی و مدل لجستیک است. صادقی و همکارانش (۱۳۹۰) در پژوهشی با استفاده از شبکه‌های عصبی مصنوعی مبتنی بر انتظارات قیمتی برای داده‌های روزانه، به مدل‌سازی و پیش‌بینی روزانه‌ی قیمت نفت خام اوپک پرداختند. سپس نتایج آنها با مقادیر پیش‌بینی شده توسط مدل آریمای براساس معیارهای اندازه‌گیری دقت پیش‌بینی، مورد مقایسه قرار گرفت. نتایج پژوهش نشان داد که شبکه‌ی عصبی مورد استفاده، نسبت به مدل آریمای از قدرت پیش‌بینی بهتری برخوردار است و قیمت نفت خام تابعی از قیمت‌های ۵ روز گذشته‌ی خود است.

۲. مبانی نظری

۲-۱. شبکه‌ی عصبی مصنوعی

براساس تعریف، شبکه عصبی مصنوعی، یک سیستم پردازش اطلاعات و یک تکنیک جدید برای بررسی داده‌های بسیار متنوع است (کرامر ۱، ۱۹۹۱) که از تعدادی زیادی واحد غیرخطی به هم پیوسته پردازشگر اطلاعات (نورون‌ها یا گره‌ها) تشکیل شده است (تاکر و جسون ۲، ۱۹۹۹) و شبکه عصبی مصنوعی از دو جهت با مغز انسان مشابهت دارد (هاکین ۳، ۱۹۹۹):

الف. کسب دانش توسط شبکه در فرآیندی به نام یادگیری یا آموزش انجام می‌شود.

ب. عوامل مرتبط کننده نورون‌ها که وزن‌های سینپتیک نامیده می‌شود، دانش کسب‌شده فیلم توسط شبکه را ذخیره می‌نمایند.

عملکرد به کار گرفته شده در شبکه مصنوعی به‌سادگی قابل فهم است: {ورودی‌های شبکه} - {خرجی‌های شبکه} (سیموتیس و همکارانش، ۲۰۰۸). شبکه‌های عصبی بر اساس جهت جریان یافتن و پردازش اطلاعات به دو دسته اصلی شبکه‌های پیش‌خور ۴ و شبکه‌های برگشتی ۵ تقسیم می‌شوند. در شبکه‌های برگشتی تبادل اطلاعات میان گره‌ها دو طرفه است. این نوع شبکه به ویژه در مدل‌سازی فرآیندهای متغیر در زمان و مکان که نیازمند ابزاری پویا برای مدل‌سازی هستند، می‌تواند گزینه مناسبی باشد. در شبکه‌های عصبی پیش‌خور نورون‌ها به طور معمول در گروه‌هایی که لایه خوانده می‌شوند، دسته‌بندی می‌شوند. یک شبکه پیش‌خور را با یک لایه ورودی آغاز و به یک لایه خروجی ختم می‌شود. میان لایه ورودی و لایه خروجی می‌تواند چندین لایه پنهان وجود داشته باشد. لایه ورودی مقادیر ورودی مدل شبکه عصبی مصنوعی را از محیط دریافت می‌کند و لایه خروجی، پاسخ سیستم شبکه عصبی را به مقادیر ورودی، به محیط بر می‌گرداند. لایه‌های مخفی اضافی توانایی شبکه را بالا می‌برند تا آمار بهتری از داده‌های ورودی

¹. Kramer, 1991.

². Takar and Johnson, 1999.


³. Hakin, 1999.

⁴. Feed – Forward Networks.

⁵. Recurrent Networks.

استخراج کند. در یک شبکه پیش‌خور نورون‌های هر لایه، اطلاعات را تنها از نورون‌های لایه پیشین دریافت کرده، پس از پردازش، شکل پردازش شده آن را تنها به نورون‌های لایه بعد، تحویل می‌دهند. بر روی عوامل مرتبط کننده نورون‌های هر لایه به نورون‌های لایه بعد مقادیری وجود دارد که وزن‌های سینپتیک به اختصار وزن نامیده می‌شوند. عملیات منتهی به محاسبه مقدار خروجی نورون‌های موجود در شبکه (به استثنای نورون‌های لایه ورودی) انجام می‌شود. خروجی به دست آمده به ترتیب، پاسخ مدل شبکه عصبی به ورودی‌های داده شده به لایه ورودی خواهد بود.

شکل ۱: نحوه عملکرد شبکه‌های عصبی



مشهورترین مدل شبکه عصبی مصنوعی، پروسپترون چند لایه (MLP^1) است. در شبکه‌های عصبی چند لایه پروسپترون هر نورون حاصل ضرب خروجی نورون‌های لایه قبلی در وزن‌های میان آن نورون و نورون‌های لایه پیشین را به عنوان ورودی خام دریافت کرده، مجموع آنها را به عنوان ورودی موثر برای قرارگیری در تابع فعال‌سازی محاسبه می‌کنند.

پژوهشگران در مطالعات گوناگونی که انجام داده‌اند از توابع فعال‌ساز مختلفی استفاده کرده‌اند. با توجه به مفاهیم پایه‌ای، بیشتر توابع غیرخطی که به عنوان تابع فعال‌ساز در نظر گرفته می‌شوند، عملکرد مناسبی از شبکه عصبی در مقایسه با روش‌های آماری (مدل‌های براساس رگرسیون) به دست می‌دهد؛ اما گرایش بیشتر پژوهشگران در استفاده از توابع فعال‌ساز کراندار بوده است. مشهورترین تابعی از این دست که به طور گسترده در پارادیم MLP استفاده شده است، تابع سیگموئید^۲ است.

۲-۲. مدل آریمما

پیش‌بینی مقادیر متغیر براساس مدل‌های آریمما به روش باکس - جنکینز معروف است. این روش صرفاً در خصوص سری‌های زمانی پایا به تحلیل می‌پردازد. در فرآیند $ARIMA(p,d,q)$ و p, d, q به

^۱. Multi - Layer perceptron.

^۲. تابع سیگموئید (Sigmoid) از بالا به پایین کراندار و اکیداً صعودی است و تابعی است که در همه جا پیوسته و مشتق پذیر است. دامنه این تابع، مجموعه اعداد حقیقی و برد آن، مجموعه اعداد حقیقی بین صفر و یک می‌باشد.

$$Out = \frac{1}{1 + \exp(-net_j)}$$

ترتیب تعداد جملات خود رگرسیون ۱، مرتبه تفاضل‌گیری و تعداد جملات میانگین متحرک می‌باشند. در صورتی که d برابر با صفر گردد فرآیند آریما تبدیل به فرآیند آریما می‌شود. این فرآیند دارای ۳ مرحله شناسایی، تخمین و تشخیص دقت پردازش است. در مرحله شناسایی مدل‌های آزمایش با استفاده از معیارهای مربوطه مشخص می‌شوند. سپس در مرحله دوم به تخمین پارامترها براساس مدل شناسایی شده پرداخته می‌شود. در نهایت مرحله بازبینی تشخیص مدل است که در این مرحله کفایت و مناسب بودن مدل تخمین زده شده، با استفاده از معیارهای مربوطه مورد آزمون قرار می‌گیرد. اگر مدل نامناسب تشخیص داده شود باید مورد اصلاح و تعدیل قرار گیرد و برای تحقق این امر مراحل قبلی برای مدل‌های جدید مجدداً به کار برده می‌شود. نهایتاً هنگامی که بهترین مدل تشخیص داده شد، با استفاده از آن به پیش‌بینی مقادیر آینده سری زمانی پرداخته می‌شود.

۳. ساختار الگو

۳-۱. فرضیه پژوهش

مدل غیرخطی (شبکه‌های عصبی مصنوعی) توانایی پیش‌بینی نقدینگی مورد نیاز دستگاه‌های خودپرداز بانک را با خطای کمتری نسبت به مدل خطی (ARIMA) دارد.

۳-۲. ساختار الگو پژوهش

جامعه آماری پژوهش، کلیه شعب بانک مهر اقتصاد استان خراسان رضوی از تاریخ ۱۳۸۶/۴/۱-۱۳۸۹/۱۲/۱ (۴۵ ماه) است. داده‌های مورد استفاده در این پژوهش برداشت وجه نقد از دستگاه‌های خودپرداز است که از سرپرستی کل بانک مهر اقتصاد استخراج شده است. این داده‌ها از دو بخش تشکیل شده‌اند. نخست، داده‌های مربوط به دوره‌ی ۱۳۸۶/۴/۱ تا ۱۳۸۹/۷/۱ (۸۰٪ داده‌ها) برای آموزش شبکه و بخش دوم، از ۱۳۸۹/۸/۱ تا ۱۳۸۹/۱۲/۱ (۲۰٪ داده‌ها) برای آزمایش، اعتبارسنجی و مقایسه مدل شبکه‌ی عصبی پیش‌خور با فرآیند آریما مورد استفاده قرار می‌گیرد. جهت بررسی مدل شبکه‌های عصبی از نرم افزار مطلب ۲ و مدل آریما از ایویوز ۳ استفاده شده است.

تعداد نمونه مورد مطالعه در این پژوهش که در مجموع ۷ دستگاه خودپرداز بوده است، با استفاده از روش حذفی و با توجه به معیارهای زیر انتخاب گردید:

اولاً: حداقل ۴ سال سابقه فعالیت دستگاه‌های خودپرداز را داشته باشد. ثانیاً: اطلاعات شعب قابل دسترسی باشد.

متغیر پژوهش نقدینگی است که به توانایی بانک در پاسخگویی به نیازهای نقدینگی اطلاق می‌شود.

¹ AR: Auto regressive.

² MATLAB.

³ Eviews.

۴. برآورد نتایج و تجزیه و تحلیل

۱.۱. مدل‌سازی و پیش‌بینی ARIMA

برای پیش‌بینی داده‌های سری زمانی به وسیله ARIMA، ابتدا مانایی سری زمانی، بررسی و مرتبه انباشتگی (d) تعیین می‌شود. در مطالعه حاضر، سری زمانی در اولین تفاضل بر اساس آزمون دیکی- فولر تعمیم یافته (ADF^۱)، مانا و سپس تعداد جملات خودرگرسیون (P) و تعداد جملات میانگین متحرک (q)، با استفاده از توابع خود همبستگی (AC^۲) خودهمبستگی جزئی (PAC^۳) براساس مراحل باکس- جنکینز محاسبه شده است. اما از آن جایی که ممکن است مدل‌های دیگری وجود داشته باشند که مقدار آکائیک یا شوارتز کمتری داشته باشند و بر الگوی مذکور ترجیح داده شوند، مدل‌های دیگر نیز بررسی می‌شوند. بر این اساس، کمترین مقدار آکائیک مربوط به فرآیند تعداد جملات خودرگرسیون و میانگین متحرک است، که نتایج تفصیلی حاصل از برآورد آنها برای هر یک از ۷ دستگاه، در جداول ۲ تا ۸ و مقایسه مقادیر واقعی و پیش‌بینی شده براساس مدل ARIMA در نمودار ۱ تا ۷ آورده شده است.

جدول ۱: آزمون مانایی دیکی فولر بر میزان برداشت وجه نقد ۷ دستگاه خودپرداز در اولین تفاضل

	ATM1	ATM2	ATM3	ATM4	ATM5	ATM6	ATM7
1% level	-۳/۵۹	-۳/۵۹	-۳/۵۹	-۳/۵۹	۳/۵۹	-۳/۵۹	-۳/۵۹
5% level	-۲/۹۳	-۲/۹۳	-۲/۹۳	-۲/۹۳	۲/۹۳	-۲/۹۳	-۲/۹۳
10% level	-۲/۶۰	-۲/۶۰	-۲/۶۰	-۲/۶۰	۲/۶۰	-۲/۶۰	-۲/۶۰
pp t-statistic	-۵/۶۴	-۱۰/۱۱	-۴/۴۳	-۱۰/۴۹	-۱۰/۰۷	-۷/۶۵	-۴/۶۷

جدول ۲: نتایج برآوردی میزان برداشت وجه نقد خودپرداز (ATM1) در دوره ۱۳۸۶/۴/۱-۱۳۸۹/۷/۱

Variable	Coefficient (prob)	Variable	
C	۷.۱۰(۰.۰۰۰)*	R ²	۰.۸۰
AR(1)	۰.۴۸۷(۰.۰۳۷)*	Adj. R ²	۰.۷۰
AR(2)	-۰.۴۱۵(۰.۰۴۹)*	F-statistic	۴.۹۷۰
AR(3)	۰.۰۵۸(۰.۷۵۷)*	Prob (F-statistic)	۰.۰۰۱
MA(1)	۰.۱۱۲(۰.۰۴۲)*		
MA(2)	۰.۹۶۰(۰.۰۰۰)*	Durbin-watson	۲.۰۴
MA(3)	۰.۲۰۴(۰.۰۰۰)*		

ATM1: دستگاه خودپرداز شماره ۱، D.w: آزمون دوربین واتسون که احتمال آماره آن باید بین ۱.۵ تا ۲.۵ باشد،

* اعداد داخل پرانتز آماره t-statistic متغیرها در جدول رگرسیون است.


¹ Augmented Dickey-Fuller test statistic.

² Auto Coloration.

³ Partial Auto Coloration.

آماره F در جدول ۲، نشان دهنده معناداری کلی مدل‌های رگرسیونی برازش شده در سطح اطمینان ۹۵ درصد است. بنابر متدولوژی باکس-جنکینز، وقفه مربوط به بی‌معناترین ضرایب حذف می‌شوند، بنابراین ضرایب $AR(3)$ و $MA(1)$ معنادار نمی‌باشند. براساس نتایج حاصل بجز این دو سایر متغیرها از لحاظ آماری در سطح اطمینان ۹۵٪ معنادار می‌باشند. بنابراین، مدل بهینه به صورت $ARIMA(1,2,1,2,3)$ خواهد بود. ضریب تعیین الگوی برآورده شده ۰.۷۹ و مقدار آماره دوربین واتسون در این مدل برابر ۲.۰۴ است که نشان می‌دهد مدل شکل خودهمبستگی ندارد. سپس در مرحله نهایی مدل $ARIMA$ برای دستگاه خودپرداز شماره ۱، پیش‌بینی گذشته‌نگر (۸۶/۴/۱ تا ۸۹/۷/۱) و پیش‌بینی آینده‌نگر (۸۹/۸/۱ تا ۸۹/۱۲/۱) روند میزان برداشت وجه با استفاده از اطلاعات موجود صورت گرفت. نتایج این بررسی در نمودار ۱ ارائه شده است.

نمودار ۱: مقادیر واقعی و پیش‌بینی میزان برداشت وجه نقد ATM1 با استفاده از روش ARIMA



جدول ۳: نتایج برآوردی میزان برداشت وجه نقد خودپرداز (ATM2) در دوره ۱۳۸۶/۴/۱ - ۱۳۸۹/۷/۱

Variable	Coefficient (prob)	Variable	
C	۸.۲۸(۰.۰۰۰)*	R ²	۰.۶۹
AR(1)	-۰.۲۱۲(۰.۰۴۶)*	Adj. R ²	۰.۵۷
AR(3)	۰.۷۰۳(۰.۰۰۰)*	F-statistic	۲۲.۴۸۸
MA(1)	۰.۱۴۷(۰.۲۶۸)*	Prob (F-statistic)	۰.۰۵۲
MA(2)	-۰.۲۱۵(۰.۰۴۵)*	Durbin-watson	۱.۹۷
MA(3)	-۰.۹۰۰(۰.۰۰۰)*		


ATM2: دستگاه خودپرداز شماره ۲، D.w: آزمون دوربین واتسون که احتمال آماره آن باید بین ۱.۵ تا ۲.۵ باشد،

* اعداد داخل پرانتز آماره t-statistic متغیرها در جدول رگرسیون است.

آماره F در جدول ۳، نشان دهنده معناداری کلی مدل‌های رگرسیونی برازش شده در سطح اطمینان ۹۵ درصد است. بنا بر متدولوژی باکس-جنکینز، وقفه مربوط به بی‌معناترین ضرایب حذف می‌شوند، بنابراین ضریب $MA(1)$ معنادار نمی‌باشد. براساس نتایج حاصل بجز این متغیر، سایر متغیرها از لحاظ آماری در سطح اطمینان ۹۵٪ معنادار می‌باشند. بنابراین، مدل بهینه به صورت $ARIMA(1,3,1,2,3)$ خواهد بود. ضریب تعیین الگوی برآورده شده ۰.۶۹ و مقدار آماره دوربین واتسون در این مدل برابر ۱.۹۷ است که نشان می‌دهد مدل شکل خودهمبستگی ندارد.

سپس در مرحله نهایی مدل $ARIMA$ برای دستگاه خودپرداز شماره ۲، پیش‌بینی گذشته‌نگر (۸۶/۴/۱ تا ۸۹/۷/۱) و پیش‌بینی آینده‌نگر (۸۹/۸/۱ تا ۸۹/۱۲/۱) روند میزان برداشت وجه با استفاده از اطلاعات موجود صورت گرفت. نتایج این بررسی در نمودار ۲ ارائه شده است.

نمودار ۲: مقادیر واقعی و پیش‌بینی میزان برداشت وجه نقد $ATM2$ با استفاده از روش $ARIMA$



جدول ۴: نتایج برآوردی میزان برداشت وجه نقد خودپرداز ($ATM3$) در دوره ۱۳۸۶/۴/۱-۱۳۸۹/۷/۱


Variable	Coefficient (prob)	Variable	
C	۶.۵۰(۰.۰۰۰) [*]	R ²	۰.۸۵
AR(1)	-۰.۳۷۷(۰.۰۷۳) [*]	Adj. R ²	۰.۷۳
AR(2)	-۰.۳۷۷(۰.۰۲۴) [*]	F-statistic	۱۵.۵۷۰
MA(1)	۰.۹۷۱(۰.۰۰۰) [*]	Prob (F-statistic)	۰.۰۰۱
MA(2)	۰.۹۸۰(۰.۰۰۰) [*]	Durbin-watson	۱.۹۴

$ATM3$: دستگاه خودپرداز شماره ۳، D.w: آزمون دوربین واتسون که احتمال آماره آن باید بین ۱.۵ تا ۲.۵ باشد، * اعداد داخل پرانتز آماره t-statistic متغیرها در جدول رگرسیون است.

آماره F در جدول ۴، نشان دهنده معناداری کلی مدل‌های رگرسیونی برازش شده در سطح اطمینان ۹۵ درصد است. بنابر متدولوژی باکس-جنکینز، وقفه مربوط به بی‌معناترین ضرایب حذف می‌شوند، بنابراین ضرایب $AR(1)$ معنادار نمی‌باشد. براساس نتایج حاصل بجز این متغیر، سایر متغیرها از لحاظ آماری در سطح اطمینان ۹۵٪ معنادار می‌باشند. بنابراین، مدل بهینه به صورت $ARIMA(1,2,1,1,2)$ خواهد بود. ضریب تعیین الگوی برآورده شده ۰.۸۵ و مقدار آماره دوربین واتسون در این مدل برابر ۱.۹۴ است که نشان می‌دهد مدل شکل خودهمبستگی ندارد.

سپس در مرحله نهایی مدل $ARIMA$ برای دستگاه خودپرداز شماره ۳، پیش‌بینی گذشته‌نگر (۸۶/۴/۱ تا ۸۹/۷/۱) و پیش‌بینی آینده‌نگر (۸۹/۸/۱ تا ۸۹/۱۲/۱) روند میزان برداشت وجه با استفاده از اطلاعات موجود صورت گرفت. نتایج این بررسی در نمودار ۳ ارائه شده است.

نمودار ۳: مقادیر واقعی و پیش‌بینی میزان برداشت وجه نقد $ATM3$ با استفاده از روش $ARIMA$



جدول ۵: نتایج برآوردی میزان برداشت وجه خودپرداز ($ATM4$) در دوره ۱۳۸۹/۷/۱-۱۳۸۶/۴/۱

Variable	Coefficient (prob)	Variable	
C	۶.۰۶(۰.۰۰۰) [*]	R ²	۰.۸۱
AR(1)	۰.۵۲۱(۰.۰۰۳) [*]	Adj. R ²	۰.۷۲
AR(2)	-۰.۳۳۳(۰.۰۷۲) [*]	F-statistic	۱۲.۲۳۲
MA(1)	-۰.۷۱۳(۰.۰۰۰) [*]	Prob (F-statistic)	۰.۰۸۷
MA(2)	۰.۷۴۰(۰.۰۰۰) [*]	Durbin-watson	۱.۹۸


$ATM4$: دستگاه خودپرداز شماره ۴، D.w: آزمون دوربین واتسون که احتمال آماره آن باید بین ۱.۵ تا ۲.۵ باشد،

* اعداد داخل پرانتز آماره t-statistic متغیرها در جدول رگرسیون است.

آماره F در جدول ۵، نشان دهنده معناداری کلی مدل‌های رگرسیونی برازش شده در سطح اطمینان ۹۵ درصد است. بنابر متدولوژی باکس-جنکینز، وقفه مربوط به بی‌معناترین ضرایب حذف می‌شوند، بنابراین ضریب $AR(2)$ معنادار نمی‌باشد. براساس نتایج حاصل بجز این متغیر، سایر متغیرها از لحاظ آماری در سطح اطمینان ۹۵٪ معنادار می‌باشند. بنابراین، مدل بهینه به صورت $ARIMA(1,2,1,1,2)$ خواهد بود. ضریب تعیین الگوی برآورده شده ۰.۸۱ و مقدار آماره دوربین واتسون در این مدل برابر ۱.۹۸ است که نشان می‌دهد مدل شکل خودهمبستگی ندارد.

سپس در مرحله نهایی مدل $ARIMA$ برای دستگاه خودپرداز شماره ۴، پیش‌بینی گذشته-نگر (۸۶/۴/۱ تا ۸۹/۷/۱) و پیش‌بینی آینده‌نگر (۸۹/۸/۱ تا ۸۹/۱۲/۱) روند میزان برداشت وجه با استفاده از اطلاعات موجود صورت گرفت. نتایج این بررسی در نمودار ۴ ارائه شده است.

نمودار ۴: مقادیر واقعی و پیش‌بینی میزان برداشت وجه نقد ATM4 با استفاده از روش ARIMA



جدول ۶: نتایج برآوردی میزان برداشت وجه نقد خودپرداز (ATM5) در دوره ۱۳۸۶/۴/۱-۱۳۸۹/۷/۱


Variable	Coefficient (prob)	Variable	
C	۸۸۱(۰.۰۰۰)*	R ²	۰.۸۵
AR(1)	۰.۴۳۸(۰.۰۰۰)*	Adj. R ²	۰.۷۱
AR(3)	-۰.۳۳۹(۰.۰۱۶)*	F-statistic	۲۷.۴۸۲
MA(1)	-۰.۴۱۹(۰.۰۰۰)*	Prob (F-statistic)	۰.۰۲۷
MA(2)	-۰.۳۴۷(۰.۰۰۰)*	Durbin-watson	۱.۹۴
MA(3)	۰.۹۴۲(۰.۰۰۰)*		

ATM5: دستگاه خودپرداز شماره ۵، D.W: آزمون دوربین واتسون که احتمال آماره آن باید بین ۱.۵ تا ۲.۵ باشد، * اعداد داخل پرانتز آماره t-statistic متغیرها در جدول رگرسیون است.

آماره F در جدول ۶، نشان دهنده معناداری کلی مدل‌های رگرسیونی برازش شده در سطح اطمینان ۹۵ درصد است. بنا بر متدولوژی باکس-جنکینز، وقفه مربوط به بی‌معناترین ضرایب حذف می‌شوند، و براساس نتایج حاصل کلیه متغیرها از لحاظ آماری در سطح اطمینان ۹۵٪ معنادار می‌باشند. بنابراین، مدل بهینه به صورت $ARIMA(1,3,1,1,2,3)$ خواهد بود. ضریب تعیین الگوی برآورده شده ۰.۸۵ و مقدار آماره دوربین واتسون در این مدل برابر ۱.۹۴ است که نشان می‌دهد مدل شکل خودهمبستگی ندارد.

سپس در مرحله نهایی مدل $ARIMA$ برای دستگاه خودپرداز شماره ۵، پیش‌بینی گذشته‌نگر (۸۶/۴/۱ تا ۸۹/۷/۱) و پیش‌بینی آینده‌نگر (۸۹/۸/۱ تا ۸۹/۱۲/۱) روند میزان برداشت وجه با استفاده از اطلاعات موجود صورت گرفت. نتایج این بررسی در نمودار ۵ ارائه شده است.

نمودار ۵: مقادیر واقعی و پیش‌بینی میزان برداشت وجه نقد ATM5 با استفاده از روش $ARIMA$



جدول ۷: نتایج برآوردی میزان برداشت وجه نقد خودپرداز (ATM6) در دوره ۱۳۸۶/۴/۱-۱۳۸۹/۷/۱


Variable	Coefficient (prob)	Variable	
C	۶.۸۵(۰.۴۹۷)*	R ²	۰.۷۸
AR(1)	۰.۹۴۶(۰.۰۰۰)*	Adj. R ²	۰.۶۳
AR(2)	-۰.۰۲۴(۰.۸۹۴)*	F-statistic	۱۷.۰۹۴
MA(1)	-۱.۳۳۴(۰.۰۰۰)*	Prob (F-statistic)	۰.۰۰۱
		Durbin-watson	۲.۰۷

ATM6: دستگاه خودپرداز شماره ۶، D.w: آزمون دوربین واتسون که احتمال آماره آن باید بین ۱.۵ تا ۲.۵ باشد، * اعداد داخل پرانتز آماره t-statistic متغیرها در جدول رگرسیون است.

آماره F در جدول ۷، نشان دهنده معناداری کلی مدل‌های رگرسیونی برازش شده در سطح اطمینان ۹۵ درصد است. بنا بر متدولوژی باکس-جنکینز، وقفه مربوط به بی‌معناترین ضرایب حذف می‌شوند، بنابراین ضریب AR(2) معنادار نمی‌باشد. براساس نتایج حاصل بجز این متغیر، سایر متغیرها از لحاظ آماری در سطح اطمینان ۹۵٪ معنادار می‌باشند. بنابراین، مدل بهینه به صورت ARIMA(1,1,1) خواهد بود. ضریب تعیین الگوی برآورده شده ۰.۷۸ و مقدار آماره دوربین واتسون در این مدل برابر ۲.۰۷ است که نشان می‌دهد مدل شکل خودهمبستگی ندارد.

سپس در مرحله نهایی مدل ARIMA برای دستگاه خودپرداز شماره ۶، پیش‌بینی گذشته‌نگر (۸۶/۴/۱ تا ۸۹/۷/۱) و پیش‌بینی آینده‌نگر (۸۹/۸/۱ تا ۸۹/۱۲/۱) روند میزان برداشت وجه با استفاده از اطلاعات موجود صورت گرفت. نتایج این بررسی در نمودار ۶ ارائه شده است.

نمودار ۶: مقادیر واقعی و پیش‌بینی میزان برداشت وجه نقد ATM6 با استفاده از روش ARIMA



جدول ۸: نتایج برآوردی میزان برداشت وجه نقد خودپرداز (ATM7) در دوره ۱۳۸۶/۴/۱-۱۳۸۹/۷/۱

Variable	Coefficient (prob)	Variable	
C	۶.۳۲(۰.۰۲۱) [*]	R ²	۰.۳۴
AR(1)	۰.۶۹۲(۰.۳۴۵) [*]	Adj. R ²	۰.۴۱
MA(1)	-۰.۰۶۹(۰.۷۸۴) [*]	F-statistic	۱۳.۹۹۹
		Prob (F-statistic)	۰.۰۰۰
		Durbin-watson	۲.۰۱


ATM7: دستگاه خودپرداز شماره ۷، D.w: آزمون دوربین واتسون که احتمال آماره آن باید بین ۱.۵ تا ۲.۵ باشد،

* اعداد داخل پرانتز آماره t-statistic متغیرها در جدول رگرسیون است.

آماره F در جدول ۸، نشان دهنده معناداری کلی مدل‌های رگرسیونی برازش شده در سطح اطمینان ۹۵ درصد است. بنا بر متدولوژی باکس-جنکینز، وقفه مربوط به بی‌معناترین ضرایب حذف می‌شوند، و براساس نتایج حاصل کلیه متغیرها از لحاظ آماری در سطح اطمینان ۹۵٪ معنادار نمی‌باشند. بنابراین، این مدل از لحاظ اقتصادسنجی قابل تجزیه و تحلیل نمی‌باشد. ضریب تعیین الگوی برآورده شده ۰.۳۴ و مقدار آماره دوربین واتسون در این مدل برابر ۲.۰۱ است که نشان می‌دهد مدل شکل خود همبستگی ندارد.

سپس در مرحله نهایی مدل ARIMA برای دستگاه خودپرداز شماره ۷، پیش‌بینی گذشته‌نگر (۸۶/۴/۱ تا ۸۹/۷/۱) و پیش‌بینی آینده‌نگر (۸۹/۸/۱ تا ۸۹/۱۲/۱) روند میزان برداشت وجه با استفاده از اطلاعات موجود صورت گرفت. نتایج این بررسی در نمودار ۷ ارائه شده است.

نمودار ۷: مقادیر واقعی و پیش‌بینی میزان برداشت وجه نقد ATM7 با استفاده از روش ARIMA



۲.۴. مدل‌سازی و پیش‌بینی شبکه‌های عصبی

انواع مختلفی از شبکه‌های عصبی مصنوعی با توجه به اهداف پژوهش می‌تواند استفاده شود. در این پژوهش از شبکه‌های عصبی پروسپترون چند لایه با الگوریتم پس‌انتشار خطا استفاده شده است. جدول ۹ چگونگی طراحی و مدل‌سازی سری‌های زمانی برداشت وجه نقد را در شبکه‌ی عصبی نشان می‌دهد.

جدول ۹: طراحی و مدل‌سازی سری‌های زمانی برداشت وجه نقد در شبکه‌ی عصبی

نوع شبکه عصبی	پروسپترون چندلایه با الگوریتم پس انتشار خطا	تابع فعال‌سازی	سیگموئید
تعداد داده‌های آموزش	۴۰ ماه	ساختار شبکه	۱۲۱۱
تعداد داده‌های آزمایش	۵ ماه	تعداد تکرار	۱۲۰
تعداد نرون ورودی	۱۵ نرون	تعداد لایه پنهان	۱
تعداد نرون خروجی	۵ نرون	تعداد نرون‌های پنهان	۲۱ نرون

۳.۴. ارزیابی و مقایسه مدل‌های پیش‌بینی ARIMA و شبکه‌های عصبی

در پایان در جدول ۱۰، مقادیر پیش‌بینی شده توسط شبکه‌ی عصبی پروسپترون چند لایه و فرآیند ARIMA را به همراه مقادیر واقعی برای ۵ ماه آینده (۸۹/۸/۱ تا ۸۹/۱۲/۱) نشان می‌دهد. در جدول ۱۰، به منظور مقایسه‌ی قدرت پیش‌بینی فرآیند ARIMA و شبکه‌ی عصبی مصنوعی، از میانگین مربع خطای استاندارد (MSE^۱) استفاده شده است.

جدول ۱۰: مقایسه نتایج پیش‌بینی و میزان خطای دو روش شبکه‌های عصبی و ARIMA برای داده‌های آزمایش

نام دستگاه	ماه	مقادیر واقعی	پیش‌بینی عصبی	پیش‌بینی ARIMA	خطای MSE	خطای ARIMA
ATM1	۱	۱۹۴۰۷۷۰۰۰۰	۷۵۲۹۰۰۰۰۰	۶۱۱۸۶۲۵۲۷	۵.۸۹ +۱۷E	+۱۷E۱.۶۰
	۲	۱۱۱۵۱۰۰۰۰۰	۶۱۸۶۰۰۰۰۰	۵۵۱۸۲۹۵۷۰		
	۳	۱۰۰۵۵۶۵۰۰۰	۷۳۲۴۰۰۰۰۰	۹۰۸۱۲۲۳۰۶		
	۴	۱۶۵۵۶۵۰۰۰۰	۹۴۳۹۰۰۰۰۰	۱۰۷۵۲۰۱۷۵۱		
	۵	۱۹۶۰۵۰۰۰۰۰	۱۱۲۷۰۰۰۰۰۰	۷۰۸۵۵۵		
ATM2	۱	۹۴۴۷۷۲۲۲۲	۸۳۵۵۰۰۰۰۰	۸۱۳۰۹۸۹۹۰	+۱۷E۱.۷۱	+۱۷E۲.۰۳
	۲	۸۵۲۶۸۸۰۰۰	۹۰۸۵۰۰۰۰۰	۸۳۴۱۴۱۲۴۰		

^۱. $MSE = \frac{1}{r} \sum (P - A)^2$

		۷۸۵۹۳۸۷۵۶	۹۷۲۰۴۰۰۰۰	۷۴۶۰۶۰۰۰۰	۳	
		۷۵۴۱۹۰۹۱۰	۹۸۵۷۱۰۰۰۰	۹۷۶۶۳۷۰۰۰	۴	
		۷۵۴۱۹۰۹۱۰	۱۰۰۷۷۰۰۰۰	۹۸۷۶۵۴۰۰۰	۵	
+۱۷E۲.۶۵	+۱۷E۲.۴۸	۷۲۳۲۰۷۰۰۰	۱۵۳۴۰۰۰۰۰	۱۸۱۹۲۰۰۰۰	۱	ATM3
		۷۰۹۴۹۱۰۰۰	۲۶۸۹۰۰۰۰۰	۱۳۳۱۰۷۰۰۰	۲	
		۷۲۲۸۷۴۰۰۰	۲۵۷۸۰۰۰۰۰	۲۹۵۴۰۷۰۰۰	۳	
		۷۷۰۹۰۵۰۰۰	۱۱۲۴۸۰۰۰۰۰	۱۸۴۵۸۰۰۰۰۰	۴	
		۶۴۳۵۵۵۰۰۰	۸۰۵۲۰۰۰۰۰	۲۲۷۸۵۰۰۰۰	۵	
+۱۷E۱.۱۱	+۱۷E۸.۸۳	۵۲۶۷۰۱۸۱۸	۷۴۲۱۰۰۰۰۰	۵۱۸۸۹۰۰۰۰	۱	ATM4
		۷۷۸۲۷۰۲۰۲	۱۱۶۲۵۰۰۰۰۰	۷۷۳۳۷۰۰۰۰	۲	
		۴۹۶۶۸۹۹۸۰	۱۰۱۱۸۰۰۰۰۰	۴۸۵۱۲۰۰۰۰	۳	
		۱۱۶۱۳۹۰۹۲۹	۱۳۶۹۱۰۰۰۰۰	۱۱۴۵۷۲۸۰۰۰	۴	
		۱۵۸۱۹۳۱۵۶۶	۸۶۹۶۰۰۰۰۰	۱۵۸۰۳۳۰۰۰۰	۵	
+۱۷E۹.۵۳	+۱۷E۲.۰۷	+۰.۹E۱.۳۵	۱۶۰۳۰۰۰۰۰	۱۳۳۱۴۱۰۰۰۰	۱	ATM5
		۸۹۹۲۲۸۸۱۴	۱۳۰۱۰۰۰۰۰	۸۸۴۱۰۰۰۰۰	۲	
		۹۱۶۴۳۴۷۴۶	۲۰۱۲۰۰۰۰۰	۸۹۲۶۰۰۰۰۰	۳	
		+۰.۹E۱.۴۲	۳۱۹۳۰۰۰۰۰	۱۴۰۶۲۵۰۰۰۰	۴	
		۹۹۹۷۵۰۰۰۰	۱۲۴۲۲۰۰۰۰۰	۵۹۹۷۵۰۰۰۰	۵	
+۱۷E۳.۲۱	+۱۷E۷.۳۲	۷۵۲۰۱۰۰۰۰	۹۸۸۸۰۰۰۰۰	۶۰۶۷۰۰۰۰۰	۱	ATM6
		۸۳۶۳۴۶۰۰۰	۱۳۱۳۸۰۰۰۰۰	۵۷۳۵۵۰۰۰۰۰	۲	
		۶۹۲۳۲۸۰۰۰	۸۳۷۴۰۰۰۰۰	۵۴۵۶۰۰۰۰۰	۳	
		۸۳۲۸۴۹۵۰۰	۱۰۴۹۹۰۰۰۰۰	۲۰۰۱۰۰۰۰۰	۴	
		۱۳۳۷۱۷۵۰۰	۱۲۲۷۸۰۰۰۰۰	۲۸۷۲۰۰۰۰۰	۵	
+۱۷E۴.۲۵	+۱۶E۲.۴۰	۷۵۲۰۱۰۰۰۰	۲۷۰۹۱۰۰۰۰	۷۱۶۲۰۰۰۰۰	۱	ATM7
		۸۳۶۳۴۶۰۰۰	۲۷۵۲۲۰۰۰۰	۷۹۶۵۲۰۰۰۰۰	۲	
		۶۹۲۳۲۸۰۰۰	۲۷۹۸۲۰۰۰۰	۶۵۹۳۶۰۰۰۰۰	۳	
		۸۳۲۸۴۹۵۰۰	۴۱۰۷۵۰۰۰۰	۷۹۳۱۹۰۰۰۰۰	۴	
		۱۳۳۷۱۷۵۰۰	۶۰۹۰۵۰۰۰۰	۱۲۷۳۵۰۰۰۰۰	۵	

در جدول ۱۰، میزان خطا شبکه‌های عصبی مصنوعی در ۴ دستگاه خودپرداز کمتر از روش آریمما محاسبه شده است که نشان از برتری روش شبکه‌های عصبی (غیرخطی) بر مدل آریمما (خطی) است.

۵. پیشنهادات سیاست‌گذاری

این پژوهش به منظور مقایسه عملکرد مدل آریمما و شبکه‌های عصبی مصنوعی برای پیش‌بینی نقدینگی مورد نیاز دستگاه‌های خودپرداز در بانک مهر اقتصاد خراسان رضوی انجام گرفت. پیش‌بینی انجام گرفته شده توسط بهترین مدل از مدل‌های شبکه عصبی مصنوعی و آریمما، نشان دهنده برتری غیرقابل مقایسه مدل شبکه‌های عصبی مصنوعی در ۴ دستگاه خودپرداز نسبت به مدل آریمما است. در نتیجه می‌توان از مدل شبکه‌های عصبی مصنوعی به عنوان ابزاری دقیقتر برای پیش‌بینی نقدینگی در کنار دیگر روش‌ها بهره جست. این نتایج با یافته‌های المر و همکارش (۱۹۹۸)، هارنگ و همکارش (۲۰۰۱)، سیموتیس و همکارانش (۲۰۰۸)، موسوی (۱۳۸۴)، فرجام‌نیا و همکارانش (۱۳۸۶)، تهرانی و همکارش (۱۳۸۵) و صادقی و همکارانش (۱۳۹۰) مطابقت دارد.

با توجه به یافته‌های این پژوهش می‌توان پیشنهادهای زیر را برای پژوهش آتی ارائه نمود:

- در این پژوهش توجه به مدلسازی با روش غیرخطی شبکه‌های عصبی مصنوعی بوده است. در پژوهش‌های آتی میتوان از مدل شبکه‌های عصبی مصنوعی که فرآیند یادگیری‌شان متکی به روش‌های ژنتیکی یا منطق فازی ۱ است، استفاده کرد.

- از مدل شبکه‌های عصبی مصنوعی به عنوان یک مدل غیرخطی نام برده می‌شود. پس می‌توان در مطالعات آینده عملکرد این مدل را با مدل‌های غیرخطی از جمله $BVAR$ ، VAR در پیش‌بینی مقایسه نمود.

- در این پژوهش برداشت وجه نقد و پیش‌بینی به صورت ماهانه انجام گرفته است که می‌تواند این امر به صورت روزانه و یا هفتگی انجام گیرد.



منابع

- تهرانی، رضا و میرفیض فلاح بخش (۱۳۸۴). طراحی و تبیین مدل ریسک اعتباری در نظام بانکی کشور. *مجله علوم انسانی و اجتماعی دانشگاه شیراز*، ۲(۴۳): ۴۵-۶۰.
- فرجام نیا، ایمان، محسن ناصری و سید محمد مهدی احمدی (۱۳۸۴). پیش‌بینی قیمت نفت با دو روش آریمای و شبکه‌های عصبی مصنوعی. *فصلنامه پژوهش‌های اقتصادی*، ۳۲: ۱۶۱-۱۸۳.
- صادقی، حسین، محسن ذوالفقاری و مجتبی الهامی نژاد (۱۳۹۰). مقایسه‌ی عملکرد شبکه‌ی عصبی و مدل ARIMA در مدل‌سازی و پیش‌بینی کوتاه‌مدت قیمت سبد نفت خام اوپک و با تأکید بر انتظارات تطبیقی. *فصل‌نامه مطالعات اقتصادی انرژی*، ۲۸: ۲۵-۴۷.
- موسوی، سید رضا (۱۳۸۴). طراحی مدل مناسب پیش‌بینی نقدینگی مورد نیاز موسسات و نهادهای مالی با استفاده از شبکه‌های عصبی. *پایان‌نامه کارشناسی ارشد دانشگاه امام صادق (ع)*.
- Elmer, P. J. & D. M. Borowski. (1988). **An Expert system and neural networks approach to financial analysis.** *Financial Management*, 12(5): 66-76.
- Haykin, S. (1999). *Neural networks, A comprehensive Foundation*, Prentice Hall.
- Hwarng H Brian, Ang H T. (2001). **A simple neural Network for ARMA(P, q) time series.** *omega*, 29: 319-333.
- Kramer, M.A. (1991). Nonlinear orincipal component analysis using outoassociative nrural networks. *Alche Journal*, 37: 233-243.
- Simuts, R., D., Bastina, L., Friman, J., Drobino (2008), **Cash Demand Forecasting for ATMusing Neural Network and Support Vector Regressin Algorithms,** *Kaunas University, Tecnology, Student UG*, 48-327, 51368 Kaunas.p 416-421.
- Simuts, R., D., Bastina, L., Friman, J., Drobino (2009). **Enhanced supervision of automatic teller machines via autoassociative neural networks.** *Applied Stochastis Models and Data Analysis*, 450-454.
- Snellman, H., M., Viren (2006). **ATM networks and cash usage, Bank of Finland,** 21, 1-33.

Forecasting Needful Liquidity Automatic Teller Machines (ATM) With Linear Model (ARIMA) and Non Linear (Neural Networks)

Ebrahim Abbasi¹, Fatemeh Rastegarnia², Fahimeh Ebrahimi³

Received: 3 December 2014 **Accepted:** 8 March 2015

The aim of this study is forecasting needful liquidity automatic teller machines (ATM) with two linear model and non Linear. Providing financial resources at ATM machines, since it is important that is necessary to keep activity ATM to provide cash into applicant and security cash in machine. Results of Such analysis make it possible to can be necessary prediction for providing financial resources of ATM such as intelligent and maintain it active during peak demand hours. The statistical case of the research consisted of 7 ATMS of Economic Mehr Bank in Khorasan Razavi during the years 1386-1389. In this study, determining amount of cash taking from ATM using nonlinear method of artificial neural networks with multi-layer perception structure and error back propagation algorithm and linear method of ARIMA is examined to choose an optimal model. Demand of cash taking from date 1386/4 till 1389/7 (40 months) as training data and from the Aban data of 1389 till the end of Esfand 1389 is intended as Test data. The finding results indicate mastery artificial neural networks model to ARIMA model in predict needed cash of an ATM from economic Mehr bank.


Classification of JEL: *C53, E37, Q30*

Key words: *neural networks, ARIMA, predict, cash, ATM, economic, mehr bank*

¹.Associate professor, member of Faculty of Alzahra University,

².M.A. in Accounting, Teacher of Saeed Academy Institution

³.M.A. in Governmental-financial management, Islamic Azad university of Aliabad katol.



نفت، برنامه ششم توسعه و اقتصاد مقاومتی داود دانش جعفری، سمانه کریمی	۱	Oil, 6 th Development Plan, Resistive Economy Davod Daneshjafari, Samane Karimi	1
مدیریت پیشگیری از جرم در ایران اکبر علیوردی نیا	۳۷	Crime Prevention Management in Iran Akbar Aliverdinia	37
پیشبینی نقدینگی مورد نیاز دستگاه های خودپرداز با استفاده از مدل خطی (ARIMA) و غیر خطی (شبکه های عصبی) ابراهیم عباسی، فاطمه رستگاریا، فهیمه ابراهیمی	۵۹	Forecasting Needful Liquidity Automatic Teller Machines (ATM) With Linear Model (ARIMA) and Non Linear (Neural Networks) Ebrahim Abbasi, Fatemeh Rastegarnia, Fahimeh Ebrahimi	59
اثرات مقایسه ای متقارن و نامتقارن شوک های نفتی بر ارزش افزوده بخش های کشاورزی و صنعت زهره وحیدی، وحید شقاقی شهری، فرهاد پهلوانزاده	۷۷	The Symmetric and Asymmetric Effects of Oil Shocks on the Agricultural and Industry Value Added Zahra Vahidi, Vahid Shaghaghi, Farhad Pahlevanzade	77
تأثیر سیاست های پولی و مالی بر ارزش افزوده بخش صنعت در راستای سیاست های کلی بخش صنعت کیومرث شهبازی، الهام کریم زاده	۹۳	Impacts of Monetary and Fiscal Policies on Value Added of Industrial Sector in Iran in Line With the General Policies of the Industrial Sector Kiumars Shahbazi, Elham Karimzadeh	93
تدوین برنامه راهبردی توسعه گردشگری روستایی ایران علی حاجی نژاد، ابوذر پایدار، فاطمه باقری، ناصر عبدی	۱۱۱	Projection of the Strategic Planning of Iran Rural Tourism Development Ali Hajinejad, Aboozar Paidar, Fatemeh Bagheri, Naser Abdi	111
چالش های گفتمان سیاست خارجی ایران در راستای دگرگشت های نوپدید در سامانه ی ژئوپلیتیک جهانی افشین متقی، مصیب قره بیگی	۱۳۷	Iran's Foreign Policy Challenges Along With the Contemporary Evolutions in the Geopolitical Systems of the World Afshin Mottaghi, Mosayeb GharehBeygi	137