

دسترسی در سایت <http://jnrm.srbiau.ac.ir>

دوره ششم، شماره بیست و سوم، فروردین و اردیبهشت ۱۳۹۹

شماره شاپا: ۵۸۸-۲۵۸۸X



بزهش‌های نوین در ریاضی



دانشگاه آزاد اسلامی، واحد علوم و تحقیقات

پیش بینی هوشمند نقدینگی دستگاه‌های خودپرداز بر مبنای تقاضای مشتریان

ندا کیانی¹، قاسم توحیدی^{2*}، شبنم رضویان³، نصرت الله شادنوش¹، مسعود صانعی²

¹دانشکده مدیریت، دانشگاه آزاد اسلامی، واحد تهران مرکزی، تهران، ایران

²گروه ریاضی کاربردی، دانشکده علوم، دانشگاه آزاد اسلامی، واحد تهران مرکزی، تهران، ایران

³گروه ریاضی، دانشکده فنی، دانشگاه آزاد اسلامی، واحد تهران جنوب، تهران، ایران

تاریخ ارسال مقاله: ۱۳۹۷/۰۷/۰۳ تاریخ پذیرش مقاله: ۱۳۹۸/۰۲/۰۲

چکیده

تزریق بیش از اندازه وجه به خودپردازها موجب تحمیل هزینه اضافی به بانک و کمبود وجه در دستگاه‌ها موجب نارضایتی مشتریان و به خطر افتادن برند بانک خواهد شد. برای این منظور باید در دستگاه‌های خودپرداز وجه نقد قابل ملاحظه‌ای تزریق شود تا پاسخگوی نیاز مشتریان باشد؛ اما تأکید بر این رویه ممکن است سبب رسوب پول در دستگاه‌ها شده و زبان‌های اقتصادی برای بانک به همراه داشته باشد. بنابراین، بانک‌ها همان‌طور که به مدیریت نقدینگی در شعب می‌پردازند، باید با توجه به شرایط زمانی، مکانی و اقتصادی به مدیریت نقدینگی دستگاه‌های خودپرداز نیز بپردازند. مهمترین گام در این راستا تشخیص میزان تقاضای وجه نقد مشتریان است. بدین منظور میانگین تراکنشهای 9 ماه سال 95 برای 1377 دستگاه خودپرداز مورد سنجش قرار داده شده و در این مقاله سعی شده است تا با پیدا کردن یک الگوی رفتاری از مشتریان با استفاده از شبکه عصبی سری زمانی پویا (NARX) روند نقدینگی دستگاه‌های خودپرداز پیش بینی شود. نتایج بدست آمده نشان می‌دهد که مدل طراحی شده با شبکه عصبی پویا نسبت به مدل‌های کلاسیک از کارایی بهتری برخوردار بوده است.

کلمات کلیدی: شبکه عصبی پویا، مدیریت نقدینگی، سری زمانی

۱- مقدمه

نظام بانکی روزانه با تقاضاهای جدیدی از سوی مشتریان روبرو می‌شود. که از آن جمله می‌توان به ارائه خدمات بانکی از طریق دستگاه‌های خودپرداز اشاره نمود که نزدیکترین راه برای برطرف کردن نیازهای مشتریان است این عرصه میدان رقابت بانکها می باشد از این رو بقای بانکها منوط به بهره‌گیری هوشمندانه از این فرصت می‌باشد بدین صورت که با مدیریت نقدینگی دستگاه‌های خودپرداز و کاهش زمان سرویس دهی و افزایش سرعت نقل و انتقال اطلاعات کاربران و کاهش خرابی‌های دستگاه در بهبود خدمات‌دهی به رقابت بپردازند.

یک پیش بینی دقیق می‌تواند ریسک اخذ یک تصمیم را به حداقل رسانده و استفاده از فرصت‌های موجود را حداکثر کند. در حقیقت کوچکترین تصمیمی را نمی‌توان با در نظر گرفتن پیش بینی عواقب آن انجام داد. تمام بانک‌ها یا شرکت‌های تابعه آن‌ها با در اختیار داشتن مسئولیت پول‌گذاری و شارژ دستگاه‌های خودپرداز همواره با این سوال اساسی روبرو است که مصرف هر دستگاه خودپرداز چقدر می‌باشد و چه زمانی موجودی دستگاه به پایان می‌رسد. با پیش بینی دقیق مصرف پول نقد در دستگاه‌های خودپرداز بانک‌ها قادر خواهند بود با استفاده از روش‌های مرسوم بهینه‌سازی هزینه فرایند پول‌گذاری در دستگاه‌ها را به حداقل برسانند. همچنین مدیریت بانک قادر خواهد بود که برنامه ریزی استراتژیک شرکت را بر مبنای برآورد دقیق مصرف دستگاه‌ها و همچنین پارامترهای موثر در مصرف پول نقد در هر دستگاه تبیین کند [1].

مطالعات و پژوهش‌های انجام گرفته در زمینه پیش بینی مصرف پول نقد در دستگاه‌های خود پرداز نشان می‌دهند که می‌توان با مدل‌سازی رفتار داده‌های تاریخی بر مبنای پارامترهای تاثیر گذار، مصرف پول نقد در این دستگاه‌ها را با دقتی قابل قبول پیش بینی کرد. پارامترهای موثر معرفی شده در ادبیات موضوع عبارتند از: مصرف میانگین ماهانه، هفتگی و روزانه، پارامترهای تقویمی نظیر: روز هفته، تعطیلات و نوع تعطیلات، رویداد‌های مالی تاثیر گذار نظیر واریز یارانه‌ها در ایران و زمان‌های واریز حقوق‌ها و مستمري‌ها و نیز پارامترهای جغرافیایی خاص هر دستگاه نظیر واقع شدن در نزدیکی مراکز

خرید یا ادارات و اماکن خاص، و همچنین پارامترهای دیگری که با مطالعات کمی پیش رو استخراج می‌گردند [2,3].

هدف اصلی مدل‌سازی سریهای زمانی، دادن نظم خاص به مشاهدات وابسته به زمان است تا بر اساس آن بتوان آینده را پیش‌بینی کرد؛ به عبارت دیگر، مهم‌ترین هدف تجزیه و تحلیل سریهای زمانی یافتن مدل‌تغییرات و پیش‌بینی آینده آن است. سری‌های زمانی به لحاظ نوع متغیرها می‌توانند پیوسته، یا گسسته باشند نظیر میانگین برداشت‌های ماهانه دستگاه‌های خودپرداز، اگر سری‌های زمانی پیوسته توسط فاصله‌های زمانی ثابت شوند آنگاه سری‌های گسسته به دست می‌آید [4].

هموارسازی نمایی^۱ و مدل میانگین متحرک یکپارچه خود بازگشتی (ARIMA) باکس-جنکینز^۲ از معروف‌ترین روشهای آماری در زمینه پیش‌بینی هستند. ماهیت روشهای آماری به گونه‌ای است که در محیطهای با تغییرات کم به خوبی قادر به پیش‌بینی هستند، اما در محیطهای دارای اغتشاش نمی‌توانند تقریب خوبی از تغییرات محیطی را تخمین بزنند. روش‌های کلاسیک و مرسوم پیش‌بینی سری‌های زمانی نظیر میانگین متحرک و اتو رگرسیون و ترکیبات حاصله از این مدل‌ها نظیر SARIMA، در مدل‌سازی رفتارهای غیر خطی و معلول به پارامترهای زیاد، کارایی چندانی ندارند و در مقابل روش‌های مبتنی بر هوش مصنوعی نظیر انواع شبکه‌های عصبی یا شبکه‌های نرو فازی^۳ و رگرسیون‌های بردار پشتیبان^۴، در یافتن الگوهای غیر خطی و آشوبناک، عملکرد قابل قبولی از خود نشان می‌دهند. همچنین با توجه به این نکته که هر یک از این پیش‌بینی‌کننده‌ها با ساختار متفاوت دارای کارایی متفاوت در بازه‌های مختلف پیش‌بینی می‌باشند. ترکیب پیش‌بینی‌کننده‌ها همواره به دقت پیش‌بینی افزوده است و باعث کاهش دامنه خطا پیرامون خطای صفر و نیز انحراف معیار خطای پیش‌بینی و در نتیجه بهبود پیش‌بینی می‌گردد [5].

با توجه به آنچه که گفته شد در بالا سیموتیس (2007) در مقاله بهینه‌سازی مدیریت نقدینگی شبکه‌های خودپرداز اشاره بر این دارد که دستگاه‌های خودپرداز، دستگاه‌های مخابراتی هستند که معاملات مالی در فضای عمومی بدون نیاز به انسان

^۱ adaptive network-based fuzzy inference system (ANFIS)

^۲ Support vector machines (SVMs)

^۱ Exponential smoothing

^۲ Box-Jenkins autoregressive integrated moving average (ARIMA) model

درویش (2013) در مقاله متدلوژی به منظور بهبود پیش‌بینی نقدینگی تقاضا برای شبکه‌های خودپرداز مورد بررسی قرار داده است که مدل پیش‌بینی نقدینگی تقاضا برای شبکه‌های خودپرداز همانند تقاضا به ترتیب تاریخ نقدینگی برای هر یک از نوسان‌های زمانی خودپرداز و اغلب رفتار متغیر کاربران اضافه شده بر آن کاری چالش برانگیز است [13]. اینایسی و همکاران (2014) در مقاله‌ای با عنوان بهینه‌سازی بازپرسازی نقدینگی خودپرداز با پیش‌بینی گروه‌بندی شده تقاضا مورد بررسی قرار داده‌اند بانکها در بازپرسازی نقدینگی خودپرداز می‌خواهند از کمترین منابع (مثل نگهداری پول در خودپردازها و کامیونهای حمل پول) برای تقاضاهای بدون ثبات مشتریان استفاده کنند [14].

در مقاله ونکناش و همکاران (2014) پیش‌بینی نقدینگی تقاضا در خودپردازها بوسیله خوشه‌بندی و شبکه عصبی انجام تا پیش - بینی نقدینگی تقاضا در خودپردازها را بهبود دهد، بنحویکه پیش - بینی تقاضا نقدی برای گروهی از خودپردازها براساس شباهت الگوهای تقاضای نقدی روزانه و هفتگی می‌باشد. از دیدگاه مدیریتی، خوشه پیش‌بینی خردمندانه تقاضا نقدینگی به مدیریت عالی بانکها کمک می‌کند تا برنامه‌هایی بازپرسازی نقدینگی مشابه برای هر دستگاه خودپرداز در همان خوشه طراحی کنند. این برنامه بازپرسازی سطح خوشه می‌تواند منجر به ذخیره هزینه - های سنگین عملیاتی برای دستگاه‌های خودپرداز در مناطق جغرافیایی مشابه شود [15]. ارورا (2014) با اشاره به اینکه متدلوژی تقریبی اداره کردن نقدینگی شبکه خودپرداز با استفاده از سیستم فازی ARTMAP است که تعیین کردن میزان بهینگی نقدینگی در خودپردازهای بانک کاری بس مشکل می - باشد همانطور که تقاضا برای نقدینگی بدون ثبات سبب تغییر در رفتار مشتریان، اولویت بندی، برداشت، زمان و غیره می‌شود. یافتن بهترین تطابق بین نیازهای نقدینگی و تکمیل تقاضا تصمیم مهمی برای مقامات بانک می‌باشد. بنابراین هدف بانک اینست که میزان بهینه پول که باید در دستگاه‌های خودپرداز با کمترین هزینه فرصت قرار داده شود و همزمان میزان رضایت و نیازهای غیرمنتظره و نامطمئن مشتریان باید تصمیم بگیرند [16]. در مقاله ای دیگر در سال (2016) اورا و همکارانش به این نکته اشاره می‌کنند که تخمین و تقریب نقش مهمی در برنامه ریزی آینده ایفا می‌کند به طوریکه رهبران کسب و کار در پی کسب و تمرین این علم هستند [17]. در سال (2016) گیل و همکارانش اشاره به این دارند که دستگاه‌های خودپرداز یکی از محبوبترین خدمات بانکی بر انجام مبادلات روزمره می‌باشد. مردم از خدمات خودپرداز برای پرداخت صورتحساب، انتقال وجوه و اخذ

فراهم می‌کند [6]. همچنین وی در مقاله دیگری در (2007) با عنوان پیش‌بینی نقدینگی تقاضا خودپردازها با استفاده از شبکه عصبی تقاضای روزانه شبکه خودپرداز را پیش‌بینی و رویه‌های برآورد مسیربایی بهینه نقدینگی بر هر خودپرداز بهینه‌سازی شده است [7]. دلیچونز و همکارانش (2007) در مقاله بهینه‌سازی خرده سیستم‌های بانکی بررسی می‌کند که مدیریت بهینه نقدینگی و خدمات در دسترس یکی از مهمترین عوامل در خدمات شبکه‌های خودپرداز است [8]. سیموتس (2008) در مقاله خود با عنوان پیش‌بینی تقاضا برای خودپردازها با استفاده از شبکه‌های عصبی و الگوریتمهای بردار رگرسیون گفته مدیریت کارآمد نقدینگی می‌تواند هزینه‌های مالی نقدینگی استفاده نشده را کاهش دهد، این قسمتی از کار دستگاه‌های خودپردازست که عملیات نظارت بر نقدینگی را به طور اتوماتیک انجام می - دهند [9]. دلیچونز و همکارانش (2009) در مقاله‌ای تحت عنوان هوشمندی و بهینه‌سازی خرده سیستم‌های بانکی و بهینه‌سازی و مدیریت شبکه‌های خودپرداز مطرح کرده‌اند که نقدینگی پیش - رو در خودپرداز مستلزم هزینه‌هایی است که در دو بخش مالی و عملیاتی تقسیم می‌شود [10]. اسلمن و ورن (2006) در مقاله شبکه‌های خودپرداز و مزایای نقدینگی بررسی کرده‌اند که در حالی که زمان به منظور انجام وظیفه و حفظ و نگهداری اول به نرخ سهام استفاده نشده بوسیله بهره سالیانه و دوم به خدمات خارجی و خطر سرقت وابسته است بنابراین انجام دوباره آن توسط خودپرداز به طور همزمان میزان موجودی پول را حداقل و خدمات توزیع پول را مطمئن می‌سازد بخصوص برای موسسات مالی بزرگ طبق آخرین مطالعات این بالاترین سطح مطلوبیت است. برطبق گفته سیموتس در مقاله پیش‌بینی تقاضا برای خودپردازها با استفاده از شبکه‌های عصبی و الگوریتمهای بردار رگرسیون مدیریت نقدینگی کارا باید متکی بر الگوریتمهای پیشرفته باشند که قادر می‌سازند تا به طور دقیقی عرضه و تقاضا نقدینگی پیش - بینی و اجازه می‌دهد به بانکها تا به طور فعال استفاده از پول را در سرتاسر شبکه اداره کنند. اخیرا برخی نویسندگان تلاش می‌کنند تا نقدینگی را بوسیله مدلسازی و پیش‌بینی تقاضا بهینه سازند. اگرچه واریانس بالا و تغییر فرایند تصادفی می‌تواند اطمینان بر چنین دیدگاهی را تحت تاثیر قرار دهد [11].

آرمیناس (2012) در مقاله بهینه‌سازی شبکه‌های خودپرداز با استفاده از الگوریتم ژنتیک بهینه‌سازی شده موجودی نقدینگی شبکه‌های خودپرداز به منظور ایجاد استراتژی‌های بهینه بارگذاری که قادرند تا میزان موجودی روزانه پول را حداقل کنند و همزمان خدمات توزیع نقدینگی را مطمئن سازند [12]. سعد

ارزشهای قبل که حاوی اطلاعات مفیدی نسبت به ارزشهای فعلی است. به عنوان اولین نمونه، از آنجایی که برای هر کدام از آنها ارزش تغییرات زمانی ناشناخته است ممکن است سبب حذف یا جایگزینی با یک مقدار گمشده شود. ارزش دلتا بدست آمده اساسا در ابتدا از برخی مقیاس ثابت مشتق شده که به اندازه گام زمانی بستگی دارد و به طور متوالی تغییرات دلتا مشتقات بالاتری می‌گیرد [4].

در برخی سری های زمانی نمونه ها رویه منظمی را نشان نمی‌دهند اما زمان در هر نمونه بوسیله یک ویژگی زمانبندی شده است. تفاوت زمانی بندی در اندازه گام برای هر نمونه و اختلافات متوالی بدست آمده برای دیگر خصیصه ها باید بر اندازه گام تقسیم شوند تا نرمالسازی صورت گیرد. در دیگر موارد هر ویژگی ممکن است یک تفاوت زمانی را نسبت به هر نمونه را نشان دهد به طوری که سری های زمانی از یک ویژگی به بعد نسبت به یک نمونه به بعد است. پس نیاز است تا اختلاف بین ارزش اولین ویژگی و ویژگی های بعدی برای هر نمونه بدست آورده شود [21, 22]. با توجه به آنچه گفته شد در این مقاله سعی شده برای یکسان سازی نمونه های بدست آمده از 1377 دستگاه خودپرداز ابتدا داده ها نرمال و در یک بازه 1- و 1+ تعریف و در نهایت با شبکه عصبی پویا پیش بینی صورت گیرد.

۲-۲- داده کاوی

نقش داده کاوی در کسب و کار بانکی می‌تواند به این نکته اشاره کرد که هدف نهایی داده‌کاوی، ایجاد سیستم‌های پشتیبانی و تصمیم‌گیری سازمانی است و وظیفه اصلی آن استخراج اطلاعات مفید و دانش از حجم زیاد داده‌هاست. داده-کاوی، الگوهای حاوی اطلاعات را در داده‌های موجود جست و جو می‌کند. این الگوها، می‌توانند توصیف کننده داده‌ها یا جنبه پیش بینی داشته باشند. دانش نهان استخراج شده از داده‌ها مهم‌ترین دارایی بانک یا هر سازمان دیگری شده و منشاء مزیت رقابتی و تمایز و اعتلای برند آن سازمان در نزد مشتریان خواهد بود.

از مهم‌ترین کاربردهای داده‌کاوی در صنعت بانکداری می‌توان به ارزش طول عمر و ارزش شبکه‌ای مشتریان و مدیریت نقدینگی، اعتبارسنجی مشتریان، مدیریت منابع انسانی، ارزیابی شعب و پولشویی اشاره نمود.

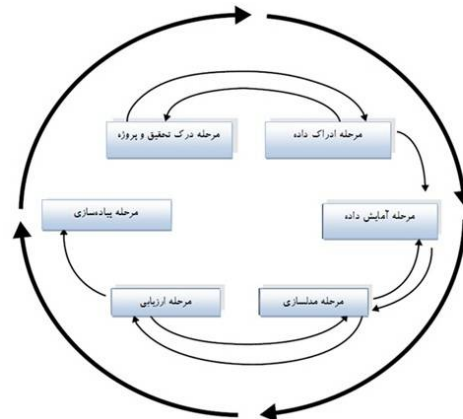
در بحث ارزش شبکه‌ای مشتریان نیز ارتباطات شبکه‌ای در حساب‌های پس‌انداز و رصد تراکنش‌های برجسته مشتریان به

پول نقد استفاده می‌کنند. پیش بینی دقیق دستگاه خودپرداز برای آینده یکی از مهمترین صفات پیش بینی شده است؛ زیرا بخش کسب و کار، نیاز روزانه مردم به میزان زیادی به این بستگی دارد [18]. وانایلا و همکارانش در سال (2018) بر اهمیت پیش بینی تقاضا وجه نقد در دستگاه های خودپرداز اشاره دارد و همچنین این امر سبب کاهش هزینه های هر معامله شده و کارایی را با کاهش بار کاری کارکنان، افزایش دقت، سرعت، صرفه جویی در وقت، پول و تلاش های مشتریان افزایش می‌دهد. بنابراین، دستگاه خودپرداز بر خدمات مشتری تاثیر می‌گذارد و منجر به رضایت مشتری می‌شود [19]. پیرامون موضوعات مطرح شده، بیلر و همکارانش در سال (2018) به این نکته اشاره دارند که استفاده از شاخص های فصلی مختلف نقش مهمی در پیش بینی نیازهای نقدی برای یک بانک دارد [20]. در بخش بعدی این مقاله، درباره داده های مورد استفاده صیحت و به روشهای مورد استفاده به منظور مدیریت نقدینگی دستگاه های خودپرداز اشاره شده است. و در بخش سه یافته های تحقیق ارائه شده از آنجا که هدف پیش بینی رفتار مشتریان براساس میانگین برداشت های ماهانه خودپردازها می باشد ابتدا با استفاده از نرم افزار کلمنتاین داده ها مورد پاکسازی و ارزیابی قرار گرفته و سپس با استفاده از این نرم افزار یک پیش بینی اولیه با استفاده از مدل‌های هموارسازی نمایی و مدل آریما انجام شده است. در نهایت از روشهای سری زمانی عصبی پویا به منظور پیش بینی دقیق رفتار مشتریان و حداکثر کردن فرصت ها و حداقل کردن ریسک در دستگاههای خودپرداز استفاده شده است و در انتها نتیجه گیری انجام شده است.

۲- داده ها و روش ها

2-1- داده های مدل سری زمانی

در داده های سری زمانی، هر نمونه داده (در این مقاله هر 1377 دستگاه خودپرداز) گام زمانی متفاوت را نشان می دهد و خصایص مربوط به ارزشها با زمان مشخص می‌شود - به عنوان مثال در این مقاله پیش بینی برداشت های ماهانه 1377 دستگاه خودپرداز در سال 95. گاهی اوقات شما نیاز دارید تا بتوانید ارزش مشخصی را در نمونه های فعلی به وسیله ارزش های مربوط به نمونه های در گذشته یا آینده جایگزین کنید. حتی در بیشتر اوقات ارزش یک خصیصه بر مبنای تفاوت بین ارزش فعلی با ارزش در برخی نمونه‌های قبلی جایگزین می‌شود. به عنوان مثال، این اختلاف را دلتا می‌نامند یعنی اختلاف بین ارزش های فعلی و



شکل 1) فرایند مدل CRISP-DM در داده کاوی

۲-۳- شبکه‌های عصبی NARX

شبکه‌ی پرسپترون چند لایه MLP، جزء شبکه‌های ایستا به حساب می‌آید. در این نوع از شبکه‌ها المان‌های بازگشتی یا پس‌خور و تاخیر زمانی وجود ندارد و خروجی‌ها به طور مستقیم از روی ورودی‌ها و با اتصالات پیش‌خور به دست می‌آیند. این نوع از شبکه‌ها در مدل‌سازی سری‌های زمانی پیچیده، که تحت تاثیر متغیرهای محرک ورودی هستند، کارایی لازم را ندارند و نیاز است تا از شبکه‌های عصبی دیگری استفاده شود. [25]

در شبکه‌های پویا، خروجی شبکه نه تنها وابسته به ورودی حال است بلکه وابسته به ورودی یا خروجی شبکه در حال و گذشته نیز می‌باشد. این شبکه‌ها به دو دسته تقسیم می‌شوند، شبکه‌هایی که فقط اتصالات پیش‌خور دارند و شبکه‌هایی که دارای اجزای بازگشتی هستند. شبکه‌ی عصبی NARX جزء شبکه‌های پویای بازگشتی می‌باشد که ورودی‌های خارجی نیز در آن، بر روی خروجی‌ها اثر می‌گذارند.

1-3-2- ساختار شبکه‌ی NARX

این شبکه‌ها به طور متداول در پیش‌بینی سری‌های زمانی استفاده می‌شوند. ساختار کلی این شبکه در شکل 2 مشاهده می‌شود.

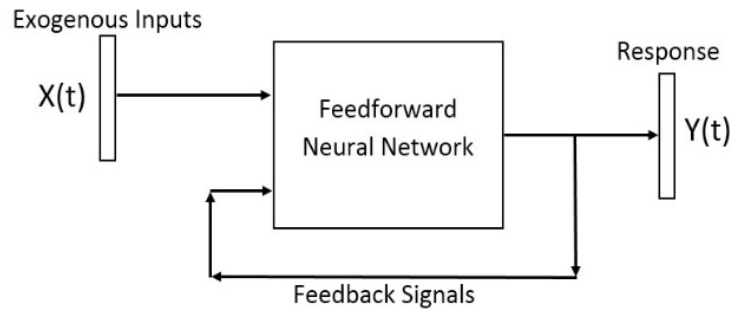
به منظور شناسایی مشتریان بالقوه و مدیریت نقدینگی مهم‌ترین کارکرد داده کاوی است.

با استفاده از داده کاوی می‌توان حجم گسترده‌ای از اطلاعات را جهت اخذ تصمیماتی بهتر و سریع‌تر مورد استفاده قرار داد. کلمنتاین¹ ابزاری قوی و کارآمدی هستند که می‌تواند وظایف تحلیل، تصمیم‌سازی، تدوین راهبرد و پیش‌بینی را مکانیزه نمایند. بنابراین، مجموع‌های از مهارت‌ها و سامانه‌های کاربردی برای گردآوری، ذخیره‌سازی، تحلیل و ایجاد دسترسی کارآمد به پایگاه‌های داده جهت نظارت مالی و درک مناسب و تصمیم‌سازی به موقع در اختیار بانک‌ها قرار می‌دهد. [23]


در این مقاله، بررسی داده‌ها بر مبنای چرخه CRISP-DM در نرم افزار کلمنتاین بوده است مراحل رایج این مدل در داده‌کاوی به قرار شکل 1 می‌باشد [21].

آنچه که حائز اهمیت است درستی از مراحل چرخه CRISP-DM باید وجود داشته باشد تکنیک‌های متفاوت مدل‌سازی انتخاب و بکاربرده و این پارامترها بر مبنای ارزش‌های بهینه‌سنجیده می‌شوند. به نوعی چندین تکنیک برای مدل‌سازی هر مسئله داده‌کاوی وجود دارد و برخی از داده فرمت خاصی را نیاز دارند. به دلیل وجود همین ارتباط نزدیک بین آماده‌سازی داده و مدل‌سازی و اغلب یک فهم اولیه نسبت به داده‌های یک مساله و بدست آوردن ایده‌ای اولیه برای محدودیت‌های پیش‌رو، این چرخه کمک شایان توجهی به انتخاب نوع مدل و انجام مدل‌سازی می‌کند [24].

به منظور مدل‌سازی از مدل‌های سری زمانی مورد استفاده در این نرم افزار از جمله مدل هموارسازی نمائی و آریما استفاده شده است.



شکل 2) ساختار کلی شکل یک شبکه‌ی NARX



شکل 3) یک نرون بازگشتی ساده

روی خروجی شبکه دارند. اولین اثر، اثر مستقیم است، چراکه یک تغییر در وزن، باعث ایجاد تغییر آنی در خروجی گام زمانی فعلی می‌شود.

این اثر می‌تواند با استفاده از پس انتشار استاندارد محاسبه شود. اثر دوم یک اثر غیر مستقیم است، چراکه برخی از ورودی‌های لایه، مانند $a(t-1)$ ، خود، تابعی از وزن‌ها هستند. برای در نظر گرفتن این اثر غیر مستقیم، برای محاسبه‌ی گرادینت‌ها باید از پس انتشار پویا استفاده کرد که از لحاظ محاسباتی بسیار پر قدرت-تر است. انتظار می‌رود پس انتشار پویا زمان بیشتری برای آموزش صرف کند. از طرفی سطح خطا در شبکه‌های پویا بسیار پیچیده‌تر از سطح خطا در شبکه‌های ایستا می‌باشد و احتمال گرفتار شدن الگوریتم آموزشی در کمینه‌های محلی بسیار زیاد است. لذا پیشنهاد شده که برای رسیدن به یک نتیجه‌ی بهینه چندین بار فرایند آموزش تکرار شود شکل 4 نشان دهنده یک شبکه عصبی سری زمانی پویا با سه لایه مخفی است. سایر بحث‌ها مانند توابع کارایی و آماده‌سازی داده‌ها در مورد شبکه‌های NARX، همانند شبکه‌های MLP می‌باشند [26].

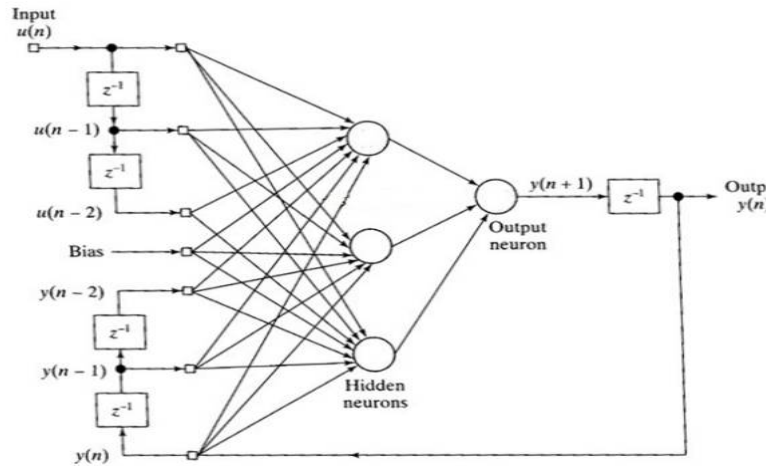
خروجی‌های شبکه با معادله‌ی زیر به دست می‌آیند:

$$Y(t) = f(Y(t-1), Y(t-2), \dots, Y(t-d_Y), X(t-1), X(t-2), \dots, X(t-d_X)) \quad (1)$$

همانطور که از شکل 2 مشخص است، مدل NARX روی یک شبکه‌ی عصبی پیشخور پیاده شده است. در این رابطه، d نشانگر میزان تاخیر زمانی شبکه است که برای ورودی‌ها و خروجی‌ها می‌تواند متفاوت باشد. همانطور که مشاهده می‌شود خروجی‌ها علاوه بر اینکه به ورودی‌های خارجی وابسته‌اند به خود خروجی‌ها در گام‌های زمانی قبل‌تر (d) نیز وابسته‌اند. و همچنین دارای قابلیت تاخیر زمانی برای ورودی‌های خارجی و همچنین ایجاد فیدبک از خروجی‌ها به ورودی‌ها هستند.

2-3-2- آموزش شبکه‌های عصبی پویا

شبکه‌های عصبی پویا همانند شبکه‌های عصبی ایستا می‌توانند با الگوریتم‌های بر پایه‌ی گرادینت مانند پس انتشار خطا و با هر تابع آموزشی مانند تابع لوببرگ - مارکاد آموزش داده شوند. کارایی این الگوریتم‌ها هنگامی که در آموزش شبکه‌های پویا استفاده می‌شوند متفاوت است و در محاسبه‌ی گرادینت، راه سخت‌تری را می‌پیمایند [25]. با دقت در نرون بازگشتی (فیدبک-دار) ساده‌ی شکل 3 مشاهده می‌شود که وزن‌ها دو اثر متفاوت



شکل 4) شبکه عصبی سری زمانی پویا

داده نمی باشد. آن یک نقطه زمانی را پیش بینی می کند و پیش بینی های خود را با اطلاعات جدید وارد می کند. این تکنیک برای پیش بینی های زمانی که به صورت روند یا فصلی یا هر دو نشان داده می شوند مفید خواهد بود. شما می توانید انتخاب کنید از انواع هموارسازی نمائی در روندها و فصلی که نشان داده شده است. مدل میانگین متحرک خود همبسته یکپارچه (ARIMA) روش - های پیچیده تری را برای مدلسازی اجزا روند و فصلی نسبت به مدل های هموارسازی نمائی فراهم می کند. و همچنین منحصرآ آنها مزیت های افزوده به متغیرهای مستقل (پیش بینی کننده) در مدل را می پذیرند. این روش دربرگیرنده رگرسیون خودکار و میانگین متحرک و نیز میزان تفاوت می باشد. همچنین متغیرهای پیش بینی کننده و تابع انتقال را برای هر یک یا همه آنها شامل می شود و نیز به طور اتوماتیک داده های پرت یا مجموعه ای از داده های پرت را شامل می شود. مدل های آرما بر خلاف مدل های هموارسازی که توصیف می کند رفتار سری های زمانی را بدون تلاش به منظور درک اینکه چرا این رفتار اتفاق افتاد است، اگر شما بخواهید تا در بگیرید پیش بینی کننده های که ممکن است کمک به توضیح رفتار سری های پیش بینی شده بکنند اغلب مفید هستند [4,22,27]. در نرم افزار کلمنتاین شما می توانید انتخاب کنید که داده های زمانی با کدامیک از این روشها مورد تحلیل و ارزیابی قرار گیرند همچنین این نرم افزار گزینه دیگری دارد که به طور اتوماتیک براساس فرایند داده مدل مطلوب انتخاب می شود. Expert Modeler به طور خودکار بهترین

۴-۲- آماده سازی داده ها

از آنجا که ابعاد متغیرهای ورودی عموماً متفاوت است، داده ها قبل از آنکه وارد شبکه شوند باید نرمال شوند. نرمال سازی⁵ به این معناست که با اعمال یک نگاشت، محدوده ی تغییرات مقادیر داده ها بین صفر تا 1+ و یا 1- تا 1+ آورده شود، با این کار داده ها بی بعد می شوند. تحقیقات نشان داده اند که نرمال سازی داده ها باعث بالا رفتن کارایی شبکه می شود. در این تحقیق داده ها به صورت مقارن بین 1- تا 1+ نرمال شده اند. تابع نرمال سازی به صورت زیر تعریف می شود:

$$X_n = \frac{2(X - X_{min})}{X_{max} - X_{min}} - 1 \quad (2)$$

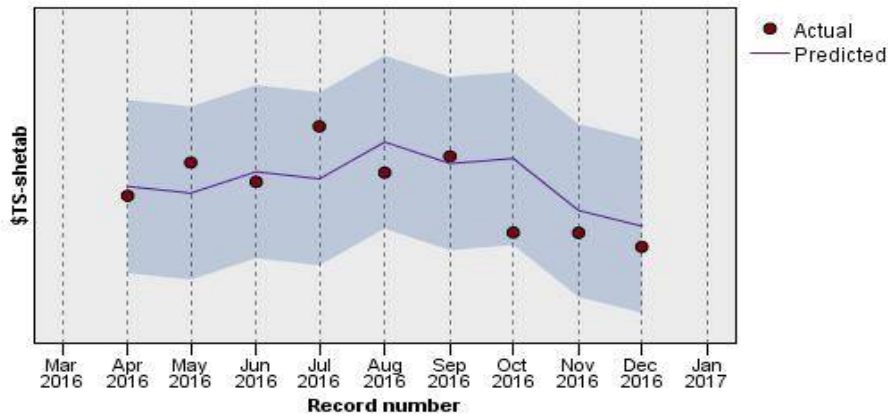
در این رابطه X مقدار نرمال نشده ی داده و X_n مقدار نرمال شده ی آن می باشد، X_{max} و X_{min} نیز به ترتیب کوچکترین مقدار عددی و بزرگترین مقدار عددی در بردار داده ها می باشند.

۳- یافته ها

۳-۱- مدل سری های زمانی با استفاده نرم افزار کلمنتاین

توابع سری زمانی از جمله هموارسازی نمائی و مدل های آرما و آرما چند متغیره (یا تابع انتقال) برای پیش بینی سری زمانی بر مبنای داده های سری زمانی تخمین زده می شوند. هموارسازی نمائی روش پیش بینی است که از ارزش وزن داده شده با توجه به مشاهدات زمانی قبلی استفاده تا ارزشهای آینده را پیش بینی کند. به همین منظور هموارسازی نمائی بر مبنای درک نظری

⁵ Normalization



شکل (5) پیش‌بینی 9 ماه 1377 دستگاه خودپرداز

پرت و اصلاح مقادیر مدل‌سازی با استفاده از گره سری زمانی انجام و پیش‌بینی در مورد فرایند تراکنشها صورت می‌گیرد همانطور که در شکل 5 می‌بینید فرایند پیش‌بینی و آنچه در واقع اتفاق افتاده است قابل رویت می‌باشد. از آنجایی که داده‌های تراکنش وابسته به زمان هستند اختلاف معناداری بین داده‌های واقعی و داده‌های پیش‌بینی مشاهده می‌شود که این اشاره به ناکارایی مدل طراحی شده دارد.

شبکه عصبی پویا از ابزارهای جدیدی است که در سیستم‌های غیرخطی و نامعین که روابط بین اجزاء و پارامترهای سیستم به خوبی شناخته شده و توصیف‌پذیر نیستند قادر به تحلیل و شبیه‌سازی می‌باشد [30]. از آنجایی که تراکنشهای دستگاه‌های خودپرداز تحت تاثیر زمان هستند و یک تقریب غیر خطی می‌باشد این شبکه برای تراکنشهای دستگاه یک مدلی کارا می‌باشد. میزان کارایی یک شبکه‌ی عصبی با استفاده از توابع مخصوصی سنجیده می‌شود. از مهم‌ترین و پرکاربردترین نوع توابع کارایی در شبکه‌های عصبی، تابع میانگین مربعات خطا⁷ و جذر آن می‌باشند. این دو تابع به صورت زیر تعریف می‌شوند:

$$MSE = \frac{1}{k} \sum_{i=1}^k (e_i)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{1}{k} \sum_{i=1}^k (e_i)^2} \quad (4)$$

e_i میزان خطاهای مشاهده شده =

مدل را بین مدل‌های هموارسازی نمائی و میانگین متحرک خود همبسته یکپارچه⁶ (ARIMA) با توجه به یکی یا چند متغیر هدف شناسایی و برآورد می‌کند بنابراین نیاز به شناسایی مدل مناسب از طریق آزمون و خطا از بین می‌رود. در همه حالات Expert Modeler برای هر متغیر هدف بهترین مدل را انتخاب و بر می‌گزیند.

اگر متغیرهای پیش‌بینی کننده مشخص باشند Expert Modeler برای ارزیابی مدل میانگین متحرک خود همبسته یکپارچه را که متغیرها یک ارتباط معنی داری با سری‌های وابسته دارند، انتخاب می‌کنند. متغیرهای مدل در صورت لزوم با استفاده از تابع ریشه مربعات و ریشه لگاریتم قابل تبدیلند. به صورت پیش فرض Expert Modeler همه مدلها از جمله هموارسازی نمائی و میانگین متحرک خود همبسته یکپارچه را بررسی و بهترین آنها از میان آنها برای هر یک از اهداف برمی‌گزیند. این قابلیت این نرم‌افزار در اختیار کاربر قرار می‌دهد تا Expert Modeler را براساس انتخاب بهترین مدل هموارسازی نمائی یا فقط میانگین متحرک خود همبسته یکپارچه محدود شود. همچنین می‌تواند به طور خودکار رخدادهای مشخص کند [29,28].

در این مقاله، چون داده‌های از 1377 دستگاه خودپرداز جمع-آوری شده است ابتدا سعی شده با استفاده از چرخه کریسپ که در بخش دو توضیح داد شده در مرحله اول داده‌ها آماده‌سازی و سپس پاکسازی لازم صورت گیرد در انتها بعد از شناسایی داده‌های

⁷ Mean Squared Error (MSE)

⁶ The Autoregressive Integrated Moving Average (ARIMA)

جدول ۱: نتایج خروجی مدل طراحی شده

S.V	mean	R	MSE	RMSE	نتایج مدل شبکه عصبی پویا
0/030976	0/0020604	0/96816	0/00096306	0/031033	All Data
0/029251	0/0026201	0/97335	0/00086161	0/029353	Train Data(70% data)
0.037467	0/00019288	0/95096	0/001397	0/037377	Validation Data(15% data)
0/031688	0/0013244	0/96135	0/0010011	0/03164	Test Data(15% data)

درصد شبکه استفاده می‌شود زمانیکه دقت شبکه بر روی داده‌های آموزشی به این مقدار رسید آموزش شبکه خاتمه می‌یابد بر اساس آزمون و خطا شبکه در این مقاله تعداد اپاک‌ها 100000 در نظر گرفته شده که در این آموزش عملکرد مدل بر مبنای میانگین خطا و مجذور خطا برای داده‌های آموزش و تست و کل داده‌ها در جدول 1 نشان داده شده است.

خروجی شبکه عصبی همان طور که در جدول یک مشاهده می‌گردد بهترین ساختار شبکه عصبی، شبکه‌ای با 5 لایه پنهان و 8 نرون می‌باشد بر طبق تعریف رگرسیون و میانگین مجذور خطا شبکه‌ای با 8 نرون در 5 لایه پنهان دارای ساختار بهتری می‌باشد و نمودارهای مربوط به این ساختار در شکل 6 نشان داده شده است.

از آنجایی که شبکه‌ی عصبی کارا و قابل اطمینان شبکه‌ای است که در عین کم بودن تابع کارایی یا همان میزان خطا، دارای ضریب همبستگی بالایی نیز باشد (نزدیک به یک) پس همانطور که در جدول یک مشاهده می‌شود ضریب همبستگی بدست آمده نشان دهنده کارا بودن مدل طراحی شده می‌باشد.

از آنجایی که پیش‌بینی‌های صورت گرفته برای ماه دهم می‌باشد برای صحت و درستی مدل علاوه بر بررسی عملکرد شبکه پیش‌بینی را برای ماه 9 انجام و روند پیش‌بینی را با آنچه که در واقعیت اتفاق افتاده در شکل 7 روند تراکنشها در نموداری نشان داده شده است. همانطور که در شکل مشاهده می‌شود میزان اختلاف پیش‌بینی‌های انجام با داده‌های واقعی بسیار نزدیک بهم بوده و درستی مدل طراحی شده مورد تایید قرار گرفته است.

در سنجش میزان کارایی شبکه‌های عصبی علاوه بر این دو تابع که گویای میزان خطای کلی پاسخ شبکه می‌باشند، از یک معیار دیگری به نام ضریب تبیین⁸ نیز استفاده می‌شود. ضریب تبیین (DC) به صورت زیر تعریف می‌شود:

انحراف نسبت به خط رگرسیون برازش

$$\sum_{i=1}^k (Y_i - \hat{Y}_i)^2 \quad (5)$$

$$\sum_{i=1}^k (Y_i - Y_i^{ave})^2 \quad (6)$$

و مقدار آن در بازه‌ی $[-\infty + 1]$ قرار دارد. در این معادله Y_i تمام مشاهده‌ها و \hat{Y}_i انحراف‌های Y_i ها در اطراف خط رگرسیون و Y_i^{ave} میانگین کل مشاهدات می‌باشد.

$$DC = 1 - \frac{\sum_{i=1}^k (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^k (Y_i - Y_i^{ave})^2} \quad (7)$$

برای سنجش کارایی یک شبکه‌ی عصبی باید هر دو پارامتر فوق مورد ارزیابی قرار گیرند، به بیان دیگر شبکه‌ی عصبی کارا و قابل اطمینان شبکه‌ای است که در عین کم بودن تابع کارایی یا همان میزان خطا، دارای ضریب تبیین بالایی نیز باشد (نزدیک به یک). این دو معیار باید به صورت همزمان ارضا شوند [31].

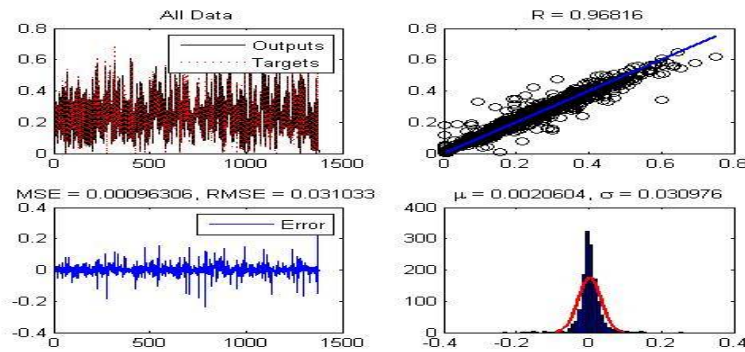
در گام اول در ایجاد شبکه عصبی و پیش‌بینی مدل تعداد نرون‌های ورودی در این مقاله بر مبنای تراکنشهای 9 ماه 1377 دستگاه خودپرداز بانک صادرات در مجموع 12393 تراکنش

صورت گرفته در کل ماه‌ها به عنوان ورودی و همچنین میزان تاخیر را بر همین مبنای تعیین و از آنجایی که تعداد اپاک⁹ها به معنای تعداد دور اجرای الگوریتم آموزش می‌باشد و همچنین نرخ آموزش¹⁰ به منظور جلوگیری از overfitting و آموزش 100


^{۱۰} Training Rate

^۸ Determination Coefficient (DC)

^۹ epoch



شکل (6) نمودارهای مدل شبکه عصبی پویا طراحی شده



شکل (7) نمایش داده های پیش بینی شده و داده های واقع

در این پژوهش، شبکه طراحی شده بر مبنای داده های واقعی، ابزاری توانمندی برای پیش بینی می باشد که قادرست ساختار غیرخطی تقاضا در دستگاه های خودپرداز را با دقت مورد انتظار تقریب بزند و نیز می تواند با ایجاد محیطی پویا، از عدم اطمینان در داده های موجود به منظور دستیابی به کاربرد عملی و با هزینه کم مقابله کند و با پیش بینی برخی از وقایع آینده سبب افزایش عملکرد و کارایی و کنترل بهتر دستگاه های خودپرداز شود و از آنجایی که مهم است میزان وجوه نقد در سطح مناسبی برای پاسخگویی به تقاضای مشتری حفظ شود؛ در چنین شرایطی، سیستم پیش بینی طراحی شده برای ایجاد یک تصویر واضح از تقاضا بسیار ضروری می باشد. یکی از مشکلات پیش رو در این پژوهش این است که بدلیل عدم دسترسی به اطلاعات روزانه برداشت از دستگاه های مربوطه و همچنین تعداد کاربرانی که روزانه از دستگاه های مورد نظر استفاده نموده اند روند پیش بینی کمی با تاخیر و به کندی انجام می شود و پیشنهاد می شود با دسترسی با این داده ها بر سرعت حل مدل افزوده شده و روند پیش بینی با دقت بهتری مورد ارزیابی قرار گیرد .

۴- نتیجه گیری

سرویس دهی به دستگاه های خودپرداز کاری پرهزینه از جهت مدیریت نقدینگی و هزینه های عملیاتی است. با بالا بودن قیمت تمام شده در ایران و اهمیت یافتن کارایی عملیاتی، بیشتر بانک ها کارایی خود را معطوف به چگونگی مدیریت وجوه نقد در دستگاه های خودپرداز نموده اند، بدین معنا که چه میزان در دستگاه ها پول نگاه دارند تا دچار مزاد یا کمبود نقدینگی نشوند. بنابراین، بانک ها همان طور که به مدیریت نقدینگی در شعب می پردازند، باید با توجه به شرایط زمانی، مکانی و اقتصادی به مدیریت نقدینگی دستگاه های خودپرداز نیز بپردازند.

در این مقاله سعی شده مدلی را بر مبنای رفتار مشتریان در طی 9 ماه از سال 95 در بین 1377 دستگاه خودپرداز ارائه دهد که نتایج مدل حاکی از آن است مدل طراحی شده یک مدل شبکه عصبی پویا با 8 ورودی و 5 لایه مخفی مدلی هوشمند با کارایی 96 درصد می باشد که قادریم با استفاده از این مدل رفتار کاربران را پیش بینی و براساس پیش بینی های صورت گرفته میزان پول - گذاری در دستگاه ها انجام شود بطوریکه روش پیشنهادی می تواند هزینه های عملیاتی را تا 80 درصد کاهش دهد. همچنین

Proc. of the ۲۰th Euro Mini Conf. on Continuous Optimization and Knowledge-Based Technologies, May ۲۰-۲۳, ۲۰۰۸, pp. 416-421.

[۱۰] D. Dilijonas, V. Sakalauskas, D. Kriksciuniene, and R. Simutis, ۲۰۰۹, "Intelligent systems for retail banking optimization - Optimization and management of ATM network system," in ICEIS ۲۰۰۹ - Proc. of the ۱۱th Int. Conf. on Enterprise Information Systems, Volume AIDSS, J. Cordeiro and J. Filipe, Eds., May ۶-۱۰, pp. ۳۲۱-۳۲۴.

[۱۱] H. Snellman and M. Virn, ۲۰۰۶, "ATM networks and cash usage," Bank of Finland, Research Discussion Papers ۲۱, November ۲۰۰۶.

[۱۲] Armenise, R., Birtolo, C., Sangianantoni, E. and Troiano, L., ۲۰۱۲, Optimizing ATM Cash Management by Genetic Algorithms, International Journal of Computer Information Systems and Industrial Management Applications, ۴, pp. 598-608.

[۱۳] Saad M. darwish, ۲۰۱۳, A Methodology to Improve Cash Demand Forecasting for ATM Network, International Journal of Computer and Electrical Engineering, Vol. ۵, No. ۴, August.

[۱۴] Ekinci, Y., Lu, J-C., Duman, E., ۲۰۱۴, Optimization of ATM Cash Replenishment with Group- Demand Forecasts, Expert Systems with Applications, doi: <http://dx.doi.org/10.1016/j.eswa.2014.12.011>.

[۱۵] Venkatesh k., V. Ravi, A. Prinzie, D. Poel, ۲۰۱۴, "Cash demand forecasting in ATMs by clustering and neural networks", European Journal of Operational Research 232, 383-392.

[۱۶] Arora N., J. Kumar R. Saini, ۲۰۱۴, "Approximating Methodology: Managing Cash in Automated Teller Machines using Fuzzy ARTMAP Network", International Journal of Enhanced Research in Science

فهرست منابع

[۱] Roger M. Hill, Soren Glud Johansen, ۲۰۰۶, "Optimal and near-optimal policies for lost sales inventory models with at most one replenishment order outstanding", Production, Manufacturing and Logistics European Journal of Operational Research 169, 111-132.

[۲] ATMmarketplace.com, "۲۰۱۰ ATM software trends and analysis," Net World Alliance, Tech. Rep., ۲۰۱۰.

[۳] FOBISS, Artificial Intelligence for Business Process Optimization, White paper, www.fobiss.com.

[۴] Salas, ۱۹۹۶. "Applied Time Series in Hydrology", Mc Graw Hill.

[۵] Abor, J., ۲۰۰۴, Technological innovation and banking in Ghana: An evaluation of Customers perception, American Academy of Financial Management.

[۶] R. Simutis, D. Dilijonas, L. Bastina, J. Friman, and P. Drobinov, ۲۰۰۷, "Optimization of cash management for ATM network," Information Technology And Control, Kaunas, Technologija, vol. 36, no. 1A, pp. 117 - 121.

[۷] R. Simutis, D. Dilijonas, L. Bastina, and J. Friman, ۲۰۰۷, "A Flexible Neural Network for ATM Cash Demand Forecasting," in Proc. ۱۱th Int. Conf. on Computational intelligence, Man-Machine System and Cybernetics, Spain, Dec. ۱۴-۱۶, pp. ۱۶۲-165.

[۸] D. Dilijonas and L. Bastina, , ۲۰۰۷, "Retail Banking Optimization System Based on Multi-agents Technology," in Proc. ۱۱th Int. Conf. on Computational intelligence, Man-Machine System and Cybernetics, Spain, Dec. ۱۴-۱۶, pp. ۲۰۳-208.

[۹] R. Simutis, D. Dilijonas, and L. Bastina, ۲۰۰۸, "Cash demand forecasting for ATM using neural networks and support vector regression algorithms," in EurOPT ۲۰۰۸ -

- [۲۵] Berry, M.J.A.; Linoff, G, ۱۹۹۷, Data Mining Techniques. For Marketing, Sales and Customer Support. Wiley Computer Publishing.
- [۲۶] Asteriou, Dimitros; Hall, Stephen G, ۲۰۱۱, "ARIMA Models and the Box-Jenkins Methodology". Applied Econometrics (Second Ed.). Palgrave MacMillan. pp. ۲۶۵-۲۸۶. ISBN ۹۷۸-۰-۲۳۰-27182-1.
- [۲۷] Xiao, X., Xu, H., & Xu, S, ۲۰۱۵, Using IBM SPSS modeler to improve undergraduate mathematical modelling competence. Computer Applications in E۲۰-۲۷.
- [۲۸] Santric-Milicevic, M., Vasic, V., & Marinkovic, J., ۲۰۱۳, Physician and nurse supply in Serbia using time-series data. Human resources for health, ۱۱(۱), ۲۷.
- [۲۹] Haykin, S. Neural Networks a Comprehensive Foundation, Second edition, Prentice Hall International Inc. engineering Education, ۲۳(۴), ۶۰۳-۶۰۹.
- [۳۰] Andrawis, R.R., Atiya, A.F., El-Shishiny, H., Forecast combinations of computational intelligence and linear models for the NN^o time series forecasting competition. International Journal of Forecasting ۲۷, ۲۰۱۱, ۶۷۲-۶۸۸.
- [۳۱] Haykin, S. Neural Networks a Comprehensive Foundation, Second edition, Prentice Hall International Inc. Technology & Engineering, ISSN: ۲۳۱۹-۷۴۶۳ Vol. ۳ Issue ۲, February, pp: ۳۱۸-326.
- [۳۲] Arora, N. and Saini, J.R., ۲۰۱۶. Estimation and approximation using neuro-fuzzy systems. International Journal of Intelligent Systems and Applications, ۸(۱), p.۹.
- [۳۳] Bhandari, R. and Gill, J., ۲۰۱۶. An artificial intelligence ATM forecasting system for hybrid neural networks. International Journal of Computer Applications, ۱۳۳(۳), pp.۱۳-۱۶.
- [۳۴] Vennila, A. and Rathnaraj, S.N., ۲۰۱۸. Impact on Customer Perception towards ATM Services Provided By the Banks Today: A Conceptual Study. International Journal of Scientific Research and Management, ۶(۰۱).
- [۳۵] BİLİR, C. and DÖŞEYEN, A., ۲۰۱۸. Optimization of ATM and Branch Cash Operations Using an Integrated Cash Requirement Forecasting and Cash Optimization Model. Business & Management Studies: An International Journal, ۶(۱).
- [۳۶] Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J., ۲۰۱۶, Data Mining: Practical machine learning tools and techniques. Morgan Kaufmann, pp ۳۱۴.
- [۳۷] Diwan, T. D., CHOUKSEY, P., Thakur, R., & LODHI, B, ۲۰۱۶, exploiting data mining techniques for improving the efficiency of time series data. In International Conference on Computers Science and Information Technology, IRNet (pp. ۴۶-۵۱).
- [۳۸] Demuth, H., Beale, M., Hagan, M. ۲۰۰۹. Neural Network Toolbox™ ۶-User's Guide, Mathworks Inc.
- [۳۹] S. A. Billings, ۲۰۱۳, "Nonlinear System Identification: NARMAX Methods in the Time, Frequency, and Spatio-Temporal Domains, Wiley, ISBN ۹۷۸-۱-1199-4359-4.