



پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA)

و غیر خطی شبکه‌های عصبی مصنوعی فازی

تاریخ دریافت مقاله: ۹۸/۰۳/۰۴ تاریخ پذیرش مقاله: ۹۸/۰۴/۱۷ امید مهری نمک آورانی^۱
رضا احتشام رانی^۲

چکیده

یکی از مهم‌ترین موارد مورد علاقه مدیران بانکی به عنوان متغیری تأثیرگذار بر صنعت بانکداری، اطلاع از وضعیت سپرده‌های بانکی است که فعالیت بانک تا حد زیادی بستگی به آن دارد. از این رو مدیران بانک‌ها علاقه‌مند هستند بدانند که میزان کل سپرده‌های بانک در زمان معینی در آینده چقدر خواهد بود. پیش‌بینی میزان سپرده‌ها، تغییر و نوسان این سپرده‌ها می‌تواند در امر برنامه‌ریزی و تصمیم‌گیری به بانک‌ها کمک نماید. در این پژوهش سعی شده است با استفاده از تکنیک‌های آماری و رویکرد مدل‌های شبکه‌های عصبی مصنوعی، مدلی مناسب با بیشترین قدرت تخمین و کمترین میزان خطا برای پیش‌بینی میزان سپرده‌ها یا همان منابع مالی به تفکیک انواع آنها برای بانک موردنظر را معرفی نماییم. برای آزمون فرضیه‌ها از اطلاعات یک بانک خصوصی طی بازه زمانی سال‌های ۱۳۸۷-۱۳۹۶ استفاده شده است. در این پژوهش، پس از بررسی توان پیش‌بین‌کنندگی روش خود رگرسیو میانگین متحرک انباشته (ARIMA) و روش شبکه‌های عصبی مصنوعی، به مقایسه‌ی این دو روش پرداخته شده است. نتایج پژوهش بر میزان سپرده‌های بانک به صورت ماهانه حاکی از آن است که روش شبکه‌های عصبی تخمین‌های بهتری نسبت به روش ARIMA ارائه می‌نمایند.

کلمات کلیدی

خود رگرسیو میانگین متحرک انباشته (ARIMA)، شبکه عصبی، منابع مالی.

۱- دانشجوی دکتری حسابداری، گروه حسابداری، دانشکده مدیریت و حسابداری، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران.
omidmehri71@gmail.com

۲- گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران. (نویسنده مسئول).
rezaehteshamrasi@gmail.com

مقدمه

امروزه بانک‌ها باید با بسیاری از چالش‌ها و تهدیدهای گوناگون مقابله کنند. بحران مالی سال ۲۰۰۸ منجر به خطرات جدی و حتی نابودی بسیاری از بانک‌ها گردید. پس از بحران مالی نگرانی‌های زیادی در مورد ثبات مالی همه موسسات مالی به وجود آمد. به علت رابطه پیچیده‌ای که بین ثبات مالی و ثبات اقتصاد کلان وجود دارد، ثبات مالی حتی در یک محیط اقتصادی پایدار نیز تضمین نمی‌شود، بنابراین توجه به ثبات مالی را نمی‌توان نادیده گرفت. در حال حاضر سیستم بانکی مهمترین عنصر مالی است و در واقع به عنوان ستون مالی اقتصاد کشور عمل می‌نماید. خصوصی‌سازی‌های صورت گرفته در سیستم بانکی ممکن است به دلیل تاثیر آن بر دولت‌ها، شرکت‌ها، سهامداران، سپرده‌گذاران و... بر اقتصاد کل جامعه هم تاثیرگذار باشد. بنابراین آگاهی از تمام عواملی که باعث ثبات مالی می‌شوند مورد توجه همگان می‌باشد (تهو فان و همکاران^۱، ۲۰۱۹).

روش خود رگرسیو میانگین متحرک انباشته (ARIMA) که خالصه شده‌ی (Autoregressive Integrated Moving Average) می‌باشد و تحت عنوان روش باکس و جنکینز^۲ شناخته می‌شود، یکی از پرکاربردترین مدل‌ها در پیش‌بینی سری‌های زمانی در طول سه دهه‌ی گذشته بوده است، اما پیش‌فرض اصلی آن این است که رابطه‌ی خطی میان ارزش‌های سری برقرار است، بنابراین رابطه‌های غیرخطی بوسیله‌ی مدل خود رگرسیو میانگین متحرک انباشته نمی‌توانند خوب توضیح داده شوند (محمدی و راعی و رحیمی، ۱۳۹۷). یکی دیگر از روش‌های مورد استفاده برای تصمیم‌گیری و پیش‌بینی که به عنوان یکی از شاخه‌های هوش مصنوعی مطرح است، شبکه‌های عصبی مصنوعی است. شبکه‌های عصبی برای حل مسائل متنوعی، مانند دسته‌بندی الگو، خوشه‌یابی، تخمین تابع، پیش‌بینی، بهینه‌سازی و کنترل در مدیریت به کار می‌رود. شبکه‌های عصبی مصنوعی دارای مزایایی از قبیل قابلیت مدل‌سازی سیستم‌های غیرخطی با وجود پیچیدگی و به صورت تکه تکه گسسته، قابلیت تعلیم، تطبیق، تحمل آسیب، ترمیم و همچنین سرعت بالای پردازش، یگانگی در تجزیه و تحلیل طراحی و تشابه با سیستم عصبی انسان می‌باشند. این دو روش جزو روش‌های منتخب شده بین پژوهش‌های پیشین بوده اما اینکه کدام یک برای پیش‌بینی منابع آبی بانک دقیق‌تر از دیگری است سوالی است که در این پژوهش به آن پاسخ داده خواهد شد. هدف اصلی در این پایان نامه مقایسه و بررسی دو روش سیستم شبکه مصنوعی چند لایه و مدل ARIMA در پیش‌بینی میزان منابع مالی بانک و انتخاب مدل مناسب‌تر در پیش‌بینی دقیق‌تر با خطای کمتر است. هدف اصلی در این مقاله مقایسه و بررسی دو روش سیستم شبکه مصنوعی چند لایه و مدل ARIMA در پیش‌بینی میزان منابع مالی بانک و انتخاب مدل مناسب‌تر در پیش‌بینی دقیق‌تر

پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) /.. مهری نمک آورانی و احتشام رائی

با خطای کمتر است. بر این اساس در این پژوهش سعی شده است با استفاده از تکنیک‌های آماری و رویکرد مدل‌های شبکه‌های عصبی مصنوعی مدلی مناسب با بیشترین قدرت تخمین و کمترین میزان خطا برای پیش‌بینی میزان سپرده‌ها یا همان منابع مالی به تفکیک انواع آنها برای بانک سامان در آینده پیش رو را معرفی نماییم. بنابراین مسأله اصلی ای پژوهش اینست که چگونه می‌توانیم میزان سپرده‌های ربالی و مجموع سپرده‌های بانک سامان را با خطای کمتری پیش‌بینی کنیم؟ این تحقیق در ۴ بخش شامل؛ بخش اول مقدمه، بخش دوم مبانی نظری و ادبیات پژوهش، بخش سوم روش پژوهش و بخش چهارم نتایج و پیشنهادهایی برای مطالعات آینده تنظیم شده است. تحقیق دارای دو رویکرد توصیفی - مدل سازی ریاضی است. از نظر جمع آوری اطلاعات جهت دستیابی به ادبیات و پیشینه تئوریک موضوع، تحقیق توصیفی است.

مبانی نظری و مروری بر پیشینه پژوهش

در یک تعریف کلی، فرایند پیشگویی شرایط و حوادث آینده را پیش‌بینی نامیده و چگونگی انجام این عمل پیش‌بینی کردن نامیده می‌شود (بوکوتا^۲، ۲۰۰۲). در مدیریت استراتژیک، پیش‌بینی شرایط عمومی اقتصاد، نوسانات قیمت و هزینه‌ی تغییرات تکنولوژی، رشد بازار و امثال آن در ترسیم آینده بلندمدت شرکت موثر است. به همین دلیل است که کنترل هر فرایند، منوط به پیش‌بینی رفتار دوره فرآیند در آینده است. برای مثال ممکن است که در یک دوره فرآیند دستگاهی بیش از حد معین کار کند و تعداد اقلام معیوب تولید شده افزایش یابد. بنابراین برای شناسایی به موقع این نقص باید از روش‌های مناسب پیش‌بینی استفاده نموده و نسبت به تصحیح و یا حذف آن با توجه به شرایط موجود اقدام نمود (ریفنس و همکاران^۴، ۱۹۹۷). پیش‌بینی قیمت سهام یکی از موارد جذاب و پر چالشی است که پژوهشگران زیادی را به خود جلب کرده است و رشته‌های علمی زیادی را نیز درگیر نموده است (ژانگ و همکاران^۵، ۲۰۱۸). پیش‌بینی روندها و بهبود قدرت پیش‌بینی ارزش بالایی در کاهش ریسک دارد (باساک و همکاران^۶، ۲۰۱۸). پژوهشگران همواره تمایل به بهبود مدل پیش‌بینی‌های موجود را دارند. دلیل آن این است که بهبود مدل‌های پیش‌بینی توانایی نهادها و افراد در تصمیم‌گیری در مورد سرمایه‌گذاری، برنامه‌ریزی و ایجاد استراتژی مؤثر در مورد آینده را تحت تأثیر قرار می‌دهد (آیودل و همکاران^۷، ۲۰۱۴).

مدل‌هایی که در تحلیل سری‌های زمانی مورد استفاده قرار می‌گیرند، به دو دسته مدل‌های خطی و غیرخطی تقسیم می‌شوند. مدل‌های خطی مانند مدل‌های باکس - جنکینز و یکنواخت سازی نمایی برای سری‌های زمانی خطی مناسب هستند، ولی در مدل‌سازی سری‌های زمانی مالی و غیرخطی با مشکل مواجه می‌شوند. مدل‌های فضای وضعیت نیز دسته دیگری از مدل‌های خطی هستند که ورودی آنها به

صورت ترکیب خطی یک مجموعه از بردارهای وضعیت است. در عمل انتخاب بردارهای وضعیت و ابعاد آنها کار دشواری است. مدل‌های غیرخطی از قبیل مدل‌های غیر کاهنده آستانه‌ای، یک تابع غیر خطی خاص و از پیش تعیین شده را پیش‌بینی می‌کنند. به عبارتی تابع خطی مورد استفاده در این روش‌ها مشخص است. نوع دیگر مدل‌های غیر خطی شبکه‌های عصبی مصنوعی هستند که می‌توانند هر تابعی را تخمین بزنند و فرایندهایی با رفتار ناشناخته را مدل نمایند. در آمار و اقتصادسنجی و به ویژه در آنالیز سری‌های زمانی از یک میانگین متحرک خودگردان یکپارچه (ARIMA) که یک مدل گسترده‌تر از میانگین متحرک خودگردان (ARMA^۱) است، استفاده می‌شود. این مدل‌ها در سری‌های زمانی برای فهم بهتر مدل یا پیش‌بینی آینده به کار می‌روند. این مدل‌ها در جایی که داده‌ها ناماننا^۹ باشند به کار می‌روند. مدل ARIMA به روش باکس - جنکینز عبارتست از برازاندن یک الگوی میانگین متحرک^{۱۰} تلفیق شده با خود رگرسیون^{۱۱} به مجموعه داده‌ها و بدست آوردن الگوی ریاضی شرطی در یک سری زمانی است.

شبکه‌های عصبی مصنوعی^{۱۲} سیستم‌ها و روش‌های محاسباتی نوینی برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت پیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده هستند. ایده اصلی این‌گونه شبکه‌ها (تاحدودی) الهام گرفته از شیوه کارکرد سیستم عصبی زیستی، برای پردازش داده‌ها، و اطلاعات به منظور یادگیری و ایجاد دانش قرار دارد. عنصر کلیدی این ایده، ایجاد ساختارهایی جدید برای سامانه پردازش اطلاعات است. این سیستم از شمار زیادی عناصر پردازشی فوق‌العاده به هم پیوسته با نام نورون تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کنند و توسط سیناپس‌ها (ارتباطات الکترو مغناطیسی) اطلاعات را منتقل می‌کنند. در این شبکه‌ها اگر یک سلول آسیب ببیند، بقیه سلول‌ها می‌توانند نبود آنرا جبران کرده، و نیز در بازسازی آن سهیم باشند. این شبکه‌ها قادر به یادگیری می‌باشند. منبع اصلی و الهام بخش برای این تکنیک، از آزمایش سیستم مرکزی عصبی و نورون‌ها (آکسون‌ها، شاخه‌های متعدد سلول‌های عصبی و محل‌های تماس دو عصب) نشأت گرفته است، که یکی از قابل توجه‌ترین عناصر پردازش اطلاعات سیستم عصبی را تشکیل می‌دهد. شبکه‌های عصبی در حالت کلی می‌توانند به عنوان جعبه‌های سیاهی در نظر گرفته شوند که ورودی را دریافت نموده و خروجی ایجاد می‌کنند. در یک شبکه عصبی اطلاعات پیچیده به اجزای اصلی آن تجزیه شده و این اجزا و رابطه‌های آنها با یکدیگر در وزن‌های شبکه که مشابه حافظه شبکه عمل می‌کنند، ذخیره می‌شوند. بر اساس چگونگی اتصال گره‌ها در معماری شبکه به یکدیگر، شبکه‌های عصبی به دو دسته شبکه‌های عصبی پیشخور و شبکه‌های عصبی پسخور تقسیم می‌شوند. مدل شبکه عصبی که در این پژوهش استفاده می‌شود، مدل شبکه‌های عصبی پرسپترون چند لایه^{۱۳} است که یکی از مناسب‌ترین

پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) /.. مهری نمک آورانی و احتشام رائی

مدل های شبکه عصبی مصنوعی پیش خور جهت پیش بینی سری های زمانی است. شبکه عصبی پرسپترون معمولاً بصورت چند لایه بکار می رود و اغلب برای نگاشت^{۱۴} غیر خطی استفاده می شود. در لایه اول اطلاعات ورودی بین لایه ورودی سیستم به شبکه تغذیه می شوند. در لایه خروجی، خروجی شبکه محاسبه می شود. لایه های بین لایه ورودی و لایه خروجی لایه های مخفی^{۱۵} نامیده می شوند که پردازش داده ها در آنها صورت می گیرد. علت اینکه به این شبکه ها پیش رونده گفته می شود این است که خروجی هر لایه به عنوان ورودی لایه بعد در نظر گرفته می شود. یکی از خصوصیات این شبکه این است که قاعده یادگیری با تکرار بدست می آید و مقادیر اولیه وزن ها و سایر پارامترها در ابتدا بصورت تصادفی انتخاب می شوند و به مرور و در طی مراحل مختلف آموزش مقادیر آنها تغییر می کند تا نهایتاً به مقدار ثابتی برسد. به نظر می رسد که تعداد درجات آزادی (تعداد ورودی ها، خروجی ها و نورون های هر لایه) برای طراحی یک شبکه چند لایه پیش خور زیاد باشد ولی باید توجه داشت که تعداد ورودی های شبکه و تعداد خروجی های شبکه بر اساس مسأله خاصی که شبکه قرار است حل کند، بدست می آیند (منهاج، ۱۳۸۷). شبکه های پرسپترون چند لایه می توانند با هر تعداد لایه ساخته و به کار گرفته شوند، ولی قضیه ای که ما در اینجا بدون اثبات می پذیریم، بیان می کند که یک شبکه پرسپترون سه لایه قادر است هر نوع فضایی را تفکیک کند. این قضیه که قضیه کولموگوروف^{۱۶} نامیده می شود، بیانگر مفهوم بسیار مهمی است که می توان در ساخت شبکه های عصبی از آن استفاده کرد (البرزی، ۱۳۸۰).

پیشینه پژوهش

حسینی پور و همکاران (۱۳۹۷)، در پژوهش خود با عنوان "مقایسه سه روش برنامه ریزی خطی، آرمانی و فازی در ترکیب بهینه منابع و مصارف در بانک کشاورزی"، به دنبال ارائه مدلی ریاضی بر اساس مدل های برنامه ریزی ریاضی جهت یافتن بهترین ترکیب تسهیلات و سپرده های بانک کشاورزی در سال ۱۳۹۴ بودند که ضمن رضایت مشتریان، بیشترین سود را برای بانک به دنبال داشته باشند. بر اساس نتایج، برنامه ریزی خطی و آرمانی نسبت به برنامه ریزی فازی و تخصیص فعلی بانک بیشترین سود را به دنبال خواهند داشت و سود حاصل از تسهیلات پرداختی با استفاده از برنامه ریزی خطی و آرمانی نسبت به برنامه ریزی فازی و تخصیص فعلی بانک افزایش داشته است. نتایج نشان داد که استفاده از مدل های برنامه ریزی خطی و آرمانی می توانند مدیران را در جهت تخصیص بهینه منابع به منظور بازدهی بالاتر یاری رسانند. زارعی و همکاران (۱۳۹۷)، "به مقایسه قدرت پیش بینی روش های شبکه عصبی فازی با شبکه عصبی موجک فازی در پیش بینی قیمت سهام بانک ها در بورس اوراق بهادار تهران طی سال های ۱۳۹۰ تا ۱۳۹۵" پرداختند. در این پژوهش از سیستم منطق فازی به همراه سیستم شبکه عصبی چند لایه با

ساختار بهینه‌سازی پس انتشار خطا و ماکزیمم همپوشانی تبدیل موجک گسسته برای متغیرهای نرخ ارز، نفت اوپک، طلا، شاخص کل سهام و همچنین حجم معاملات برای پیش‌بینی قیمت سهام استفاده شده است. نتایج حاصل از مدل با استفاده از تابع هزینه بروزرسانی شده انجام گرفت. نتایج پژوهش نشان داد که قابلیت اطمینان پیش‌بینی قیمت سهام بانک‌ها با شبکه عصبی موجک فازی بالای ۹۰ درصد و با شبکه عصبی فازی بالای ۸۰ درصد است. در نتیجه شبکه عصبی موجک فازی با قابلیت اطمینان بالاتری نسبت به شبکه عصبی فازی عمل می‌کند. احمدی شال و وصفی (۱۳۹۶) در پژوهشی تحت عنوان "پیش‌بینی نقدینگی بر اساس برآورد نقطه‌ای و بازه‌ای روش آریمای و مقایسه آن با روش هموارسازی نمایی دوگانه" پرداختند. در این تحقیق در کنار برآورد نقطه‌ای که ممکن است با تغییراتی که صورت می‌پذیرد تفاوت معنی‌داری داشته باشد، از برآورد بازه‌ای نیز استفاده شده است. فاصله اطمینان‌های ۸۰ و ۹۵ درصدی برای پیش‌بینی نقدینگی کشور انجام شده است که مقادیر واقعی نقدینگی را تحت پوشش قرار می‌دهند و برآورد مناسبی را در اختیار مدیران کلان قرار داده تا به هنگام برنامه‌ریزی مسائل اقتصادی در زمینه نقدینگی تغییرات ممکن را به شکل مناسبی لحاظ نمایند. نتایج حاصل از این پژوهش حاکی از آن هست که مدل آریمای پیشنهاد شده (نقطه‌ای-بازه‌ای) در مقایسه با روش هموارسازی نمایی دوگانه توانایی بالایی برای مدل‌سازی و پیش‌بینی میزان نقدینگی کشور را داراست. احتشام راثی و احسانی فر (۱۳۹۴)، در پژوهشی به بررسی پیش‌بینی نرخ ارز در بازار سرمایه با استفاده از مدل‌های میانگین متحرک خود رگرسیون انباشته و شبکه عصبی پرداختند و سپس به مقایسه این دو روش برای پیش‌بینی نرخ روزانه ارز از سال ۱۹۹۰/۱/۱ تا ۲۰۱۲/۱/۱ پرداخته شد. نتایج تحقیق نشان داد که روش شبکه‌های مصنوعی تخمین‌های بهتری نسبت به روش میانگین متحرک خود رگرسیو انباشته ارائه می‌کند. عاملی و رضانی (۱۳۹۴)، در پژوهش خود به پیش‌بینی قیمت سهام با استفاده از شبکه عصبی فازی مبتنی بر الگوریتم ژنتیک و مقایسه با شبکه عصبی فازی پرداختند. الگوریتم پیشنهادی با استفاده از داده‌های ۱۰ شرکت که هر کدام از آن‌ها دارای ۷ ویژگی بودند، ارزیابی شد. نتایج شبیه‌سازی نشان داد که با توجه به نوع شرکت‌ها، ویژگی‌های انتخابی و نوع ساختار شبکه عصبی فازی ترکیبی نتایج متفاوتی بدست می‌آید. با توجه به معیارهای مورد ارزیابی، نتایج به دست آمده برتری شبکه عصبی فازی ترکیبی را به شبکه عصبی فازی ساده نشان می‌دهد، اما بطور کلی پیش‌بینی ساختار سوگنو با الگوریتم ژنتیک دارای عملکرد بهتری نسبت به ساختار ممدانی دارد، چون تعداد پارامترهای آموزش ساختار سوگنو بیشتر است. عباسی و همکاران (۱۳۹۳) در تحقیق خود تحت عنوان "پیش‌بینی نقدینگی مورد نیاز دستگاه‌های خودپرداز با استفاده از مدل خطی (ARIMA) و غیرخطی

پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) /.. مهری نمک آورانی و احتشام رائی

(شبکه‌های عصبی)^{۱۱} به مطالعه تامین منابع مالی در دستگاه‌های خودپرداز پرداختند. این مطالعه از این نظر اهمیت دارد که لازمه فعال نگه داشتن خودپرداز در ارائه وجه نقد به متقاضیان و تامین اسکناس در دستگاه می‌باشد. 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 پس انتشار خطا و روش خطی ARIMA بررسی شده است تا مدل بهینه انتخاب شود. نتایج به دست آمده نشان دهنده برتری مدل شبکه‌های عصبی مصنوعی نسبت به مدل ARIMA در پیش‌بینی وجه نقد مورد نیاز دستگاه خودپرداز بانک مهر اقتصاد می‌باشد. بمانی و همکاران^{۱۳۹۴}، در مقاله خود درباره پیش‌بینی قیمت سهام بانک‌های پذیرفته شده در بورس اوراق بهادار تهران بر اساس مدل PCA-NN و مقایسه آن با مدل آریمای پژوهش‌هایی انجام داده و به این نتیجه رسیدند که دقت شبکه عصبی در پیش‌بینی قیمت سهام بالاتر بوده و مقدار خطای کمتری را نسبت به روش آریمای خود اختصاص داده است.

جدهاو و همکاران^{۱۷} (۲۰۱۸)، شاخص‌های بازار سهام را با الگوریتم‌های پیش‌بینی شبکه‌های عصبی مصنوعی پیش‌بینی کردند. الگوریتم ارائه شده توانایی پاسخ‌های خرید، فروش، نگهداری سهام را به شخص سرمایه‌گذار دارد. الگوریتم پیشنهادی در بازار سهام بمبئی آزمایش شد و نتایج عملکرد خوب مدل ارائه شده را نشان می‌دهد. برونو و همکاران^{۱۸} (۲۰۱۸)، در پژوهشی، از تکنیک رگرسیون بردار پشتیبانی (SVR) برای پیش‌بینی برانوو قیمت سهام سرمایه‌گذاری‌های بزرگ و کوچک استفاده کردند. نتایج پیش‌بینی شده این مدل، با مدل تصادفی فرضیه بازار کارا مقایسه شد و نتایج نشان داد که SVR دارای قدرت پیش‌بینی‌کنندگی است به ویژه هنگامی که از استراتژی به‌روزرسانی مدل به صورت دوره‌ای استفاده می‌شود. آیدینم و کاودار^{۱۹} (۲۰۱۵)، به پیش‌بینی بحران‌های مالی با استفاده از سیستم شبکه مصنوعی در کشور ترکیه پرداختند. هدف ایشان ایجاد یک سیستم آگاهی دهنده زودهنگام برای پیش‌بینی بحران‌های مالی بود. اطلاعات تحقیق این پژوهش متعلق به داده‌های اقتصادی ترکیه طی سال‌های ۱۹۹۰ تا ۲۰۱۴ بود. آن‌ها دریافتند که قدرت پیش‌بینی شبکه‌های عصبی قابل توجه است. پیش‌بینی یکی از نمونه‌های برون دامنه‌ای نشان داد که اقتصاد ترکیه به علت ناپایداری سیاسی در ریسک بالایی قرار دارد. ناین و همکاران^{۲۰} (۲۰۱۳)، یک روش ترکیبی جهت پیش‌بینی قیمت سهام Wal-Mart از بازار بورس آمریکا معرفی کرده‌اند که متشکل از دو مولفه شبکه عصبی و سیستم منطق فازی است. اولین مولفه این ترکیب، شبکه عصبی پیش‌خور^{۲۱} (FFNN) است که برای انتخاب ورودی‌هایی که ارتباط قوی با متغیرهای وابسته دارند استفاده می‌شود. یک سیستم فاصله‌ای منطق فازی نوع ۲ (IT2FLS^{۲۲}) به عنوان مولفه دوم روش پیش‌بینی ترکیبی استفاده شده است. پارامترهای

IT2FLS از طریق بکارگیری روش خوشه‌بندی K-means مقداردهی اولیه می‌شود و سپس توسط الگوریتم ژنتیک تنظیم می‌شود. نتایج تجربی نشان می‌دهد که در توصیف کارایی FFNN با انتخاب ویژگی پیچیدگی آن کاهش می‌یابد و دقت پیش‌بینی افزایش می‌یابد. بعلاوه IT2FLS عملکرد بالاتری نسبت به FLS نوع یک و FFNN دارد. یوهانگ و ویهوا^{۲۳} (۲۰۱۰)، کاربرد شبکه عصبی مصنوعی را در اقتصادهای مالی بررسی کردند. آن‌ها به مطالعه نمونه‌ای برای کاربرد شبکه عصبی مصنوعی در پیش‌بینی قیمت بازار مالی پرداختند. نتایج پژوهش نشان داد که شبکه عصبی مصنوعی یک ابزار پیش‌بینی ارزشمند در اقتصاد مالی است.

سوالات پژوهش

با عنایت به نوع پژوهش سعی بر آن داریم که به سوالات ذیل پاسخ دهیم:

- ۱- چگونه می‌توان میزان انواع سپرده‌های ریالی (قرض‌الحسنه، جاری، کوتاه مدت و بلند مدت) و مجموع سپرده‌های بانک سامان را با استفاده از روش آریمای و شبکه عصبی پیش‌بینی کرد؟
- ۲- در پیش‌بینی میزان انواع سپرده‌های بانک سامان بر اساس شاخص‌های خطای و ضریب تعیین، آیا مدل شبکه‌های عصبی چند لایه از مدل آریمای دقیق‌تر است؟

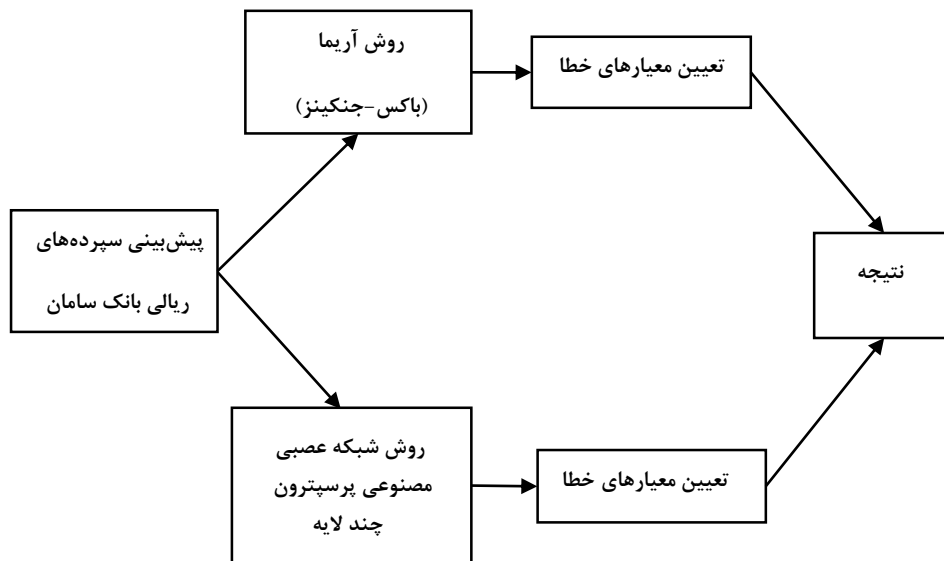
روش‌شناسی پژوهش

داده‌های مربوط به این پژوهش به صورت ماهیانه طی سال‌های ۱۳۸۷ تا ۱۳۹۶ از سپرده‌های بانک سامان جمع‌آوری شده‌اند. این داده‌ها از نوع داده‌های سری زمانی هستند زیرا روند مقادیر ماهیانه با فواصل معین و یکسان تنظیم شده‌اند. از مدل‌های ARIMA و شبکه عصبی مصنوعی فازی برای تحلیل داده‌ها استفاده شده است. میزان سپرده‌های بانک به‌عنوان متغیر وابسته در نظر گرفته شد.

مدل ARIMA با بررسی داده‌ها و در نظر گرفتن معیارهای مورد نظر، با استفاده از نرم افزار Eviews تخمین و برآورد گردید و سپس به تحلیل آن‌ها پرداخته شد. سپس با استفاده از مدل شبکه عصبی فازی و با در نظر گرفتن مقادیر مشاهده شده (میزان سپرده‌ها) به عنوان متغیر هدف (وابسته) و متغیر روند به عنوان متغیر مستقل، با استفاده از نرم افزار Matlab مقادیر خروجی مشخص و تحلیل‌های متناظر با آن‌ها انجام شد. پس از برآورد مدل و پیش‌بینی انواع سپرده‌های ریالی بانک سامان در این مطالعه به بررسی قدرت پیش‌بینی هر یک از الگوها با استفاده از معیارهای خطای پیش‌بینی و ضریب تعیین پرداخته شده است. در این مطالعه برای ایجاد شبکه از ۸۰ درصد داده‌ها به عنوان داده‌های آموزش شبکه و از ۲۰ درصد داده‌ها برای آزمون شبکه استفاده شده است. شبکه طراحی شده در این مطالعه ۲ نرون در لایه

پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) /.. مہری نمک آورانی و احتشام رائی

اول و ۱ نرون در لایه آخر داشته است. از آنجا که متغیر هدف و خروجی شبکه تنها یک سری زمانی بوده است، در لایه آخر تنها یک نرون وجود خواهد داشت. همچنین تعداد نرون‌های لایه پنهان بسته به هر سری زمانی تعیین شده است. شکل شماره (۱) نشان‌دهنده مدل مفهومی مراحل انجام کار می‌باشد:



شکل ۱- مدل مفهومی مراحل انجام کار

مدل باکس - جنکینز

مدل باکس - جنکینز مدل باکس - جنکینز یا آریمما عبارتست از برازاندن یک الگوی میانگین متحرک تلفیق شده با خود رگرسیو به مجموعه داده‌ها و بدست آوردن الگوی ریاضی شرطی در یک سری زمانی. یک مدل آریمما سه جزء دارد:

۱- خود رگرسیو

۲- میانگین یکپارچه^{۲۴}

۳- میانگین متحرک

انواع مدل‌های باکس - جنکینز به صورت ذیل بیان می‌شوند:

الف- مدل اتو رگرسیو $AR(p)$

این روش مشاهدات Z_t را به صورت تابعی از مشاهدات قبلی بیان می کند. در این مدل ε_t ها مستقل هستند و در آن φ پارامترهایی می باشند که بستگی به هر یک از p مقدار قبل در سری را معلوم می کنند.

$$Z_t = \mu_0 + \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + \varepsilon_t \quad (1)$$

(ب) مدل میانگین متحرک MA(Q)

این روش مشاهدات Z_t را به صورت تابعی از اختلالات تصادفی در دوره ی فعلی t و در دوره های قبلی بیان می کند. در این مدل α_t ها مستقل هستند و $\alpha_t, \alpha_{t-1}, \dots, \alpha_{t-q}$ اختلالات تصادفی را در دوره های $(t, t-1, \dots, t-q)$ بیان می کند و ε_t میانگین متحرک اختلال جاری α_t و اختلال های قبلی است که اختلال های قبلی دارای وزن های $\theta_t, \dots, \theta_q$ هستند. عدد q را مرتبه ی مدل میانگین متحرک می گویند و جمع وزن های θ لزوماً برابر ۱ است.

$$Z_t = \mu + \varepsilon_t \quad (2)$$

$$\varepsilon_t = \alpha_t + \theta_1 \alpha_{t-1} + \dots + \theta_q \alpha_{t-q} \quad (3)$$

(ج) مدل ARMA(p,q)

رابطه کلی با توجه به موارد بحث شده به صورت زیر است که برای سری های ایستا به کار می رود.

$$Z_t = \varphi_1 Z_{t-1} + \dots + \varphi_p Z_{t-p} + \alpha_t + \theta_1 \alpha_{t-1} + \dots + \theta_q \alpha_{t-q} \quad (4)$$

(د) مدل ARIMA(p,d,q)

این مدل تمام گروه های ذکر شده را در بر می گیرد. در این مدل p مرتبه اتورگرسیو مدل و q مرتبه میانگین متحرک مدل و d مرتبه تفاضلی مدل (جهت ایستا کردن مدل) است. یعنی آنچه که این مدل را کامل تر از مدل های قبل می نماید تبدیل مناسب جهت پایا بودن مدل است.

$$\varphi_p(B)(1-B)^d X_t = \theta(B)Z_t \quad (5)$$

$$\varphi_p(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \varphi_3 B^3 - \dots - \varphi_p B^p \quad (6)$$

$$\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \theta_3 B^3 + \dots + \theta_p B^p \quad (7)$$

که در آن $\varphi(B), \theta(B), p, q, d, \varphi_i (i = 1, 2, \dots, p), \theta_j (j = 1, 2, \dots, q)$ به ترتیب مقادیر آنی متغیر، نویز سفید در زمان t ، چند جمله ای اتورگرسیو، مرتبه میانگین متحرک، درجه تفاضل گیری و پارامترهای مدل اتورگرسیو و میانگین متحرک می باشند.

پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) / مهری نمک آورانی و احتشام رائی

ه) شرایط پایا پذیری سری های زمانی پیش بینی از طریق مدل باکس - جنکینز باید دقت کنیم که مدل $Z_t = \delta + \theta_q(B)\alpha_t$ زمانی در توصف پیش بینی سری زمانی به کار می رود که پایا باشد. منظور از سری زمانی پایا این است که مشخصه های آماری آن (مثل میانگین و واریانس) در طی زمان ثابت باشند. اگر مقادیر $\gamma_1 \gamma_2 \dots \gamma_N$ یک سری زمانی با اختلاف ثابتی حول میانگین نوسان داشته باشد در این صورت سری زمانی مورد نظر پایاست که با مشاهده نمودار داده ها می توان نتیجه گرفت که آیا سری مورد نظر پایا است یا خیر. اگر نمودار داده های $\gamma_1 \gamma_2 \dots \gamma_N$ بیانگر پایا نبودن مقادیر باشد، در این صورت می توان با گرفتن تفاضلات اولیه، مقادیر را به یک سری زمانی پایا تبدیل کنیم.

تفاضلات اولیه مقادیر $\gamma_1 \gamma_2 \dots \gamma_N$ عبارتند از

$$Z_t = Y_t - Y_{t-1} \quad (8)$$

با توجه به اینکه $t=2, \dots, N$ می باشد. اگر تفاضلات اولیه خود نیز پایا نباشند در این صورت از روش های دیگر مثل گرفتن تفاضلات ثانویه استفاده می شود.

$$Z_t = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) = Y_t - 2Y_{t-1} + Y_{t-2} \quad (9)$$

روش پیش بینی مبتنی بر شبکه های عصبی

به منظور برآورد الگوی شبکه عصبی MLP پس از طراحی انواع مختلف شبکه عصبی، بسته به مقتضیات مدل در لایه پنهان، توابع فعال سازی سیگموئید و تانژانت هیپربولیک استفاده شده و همچنین بر همین اساس مناسب ترین میزان نورون در این لایه ها تعیین شده است. همچنین استفاده از تابع فعال سازی خطی در لایه آخر با یک نورون، در نرم افزار Matlab به پیش بینی سپرده های بانک سامان پرداخته شده است و پیش از برآورد همان گونه که بیان شد، کلیه متغیرها در بازه صفر تا یک استاندارد شده اند. پس از برآورد مدل و پیش بینی انواع سپرده های ریالی بانک سامان در این مطالعه به بررسی قدرت پیش بینی هر یک از الگوها با استفاده از معیارهای خطای پیش بینی و ضریب تعیین پرداخته شده است. در این مطالعه برای ایجاد شبکه از ۸۰ درصد داده ها به عنوان داده های آموزش شبکه و از ۲۰ درصد داده ها برای آزمون شبکه استفاده شده است. شبکه طراحی شده در این مطالعه ۲ نورون در لایه اول و ۱ نورون در لایه آخر داشته است. از آنجا که متغیر هدف و خروجی شبکه تنها یک سری زمانی بوده لذا در لایه آخر تنها یک نورون وجود خواهد داشت. همچنین تعداد نورون های لایه پنهان بسته به هر سری زمانی تعیین شده است. با توجه به اینکه میزان سپرده های ریالی را به صورت زمانی در دست داریم لذا

شبکه عصبی به گونه‌ای طراحی شده که قادر است میزان این سپرده‌ها را از ابتدای شروع دوره در دسترس تا زمان t دریافت نماید و سپس قادر است میزان سپرده‌ها را در بازه زمانی t تا پایان دوره‌ای که مایل به پیش‌بینی آن هستیم، پیش‌بینی کند. این پیش‌بینی به عنوان آزمونی برای عملکرد مدل طراحی شده است.

مدل شبکه‌های عصبی پرسپترون چند لایه

در مدل شبکه عصبی پرسپترون چند لایه، بسته به مقتضیات مدل در لایه پنهان، توابع فعال‌سازی سیگموئید و تانژانت هیپربولیک استفاده شده و همچنین بر همین اساس مناسب‌ترین میزان نرون در این لایه‌ها تعیین شده است و در لایه آخر از تابع خطی به عنوان تابع فعال‌سازی استفاده شده است. الگوریتم مورد استفاده، الگوریتم لونیگ-مارکوارت است که انتخاب این الگوریتم به دلیل نرخ همگرایی بهتر و سریعتر بودن این الگوریتم در مسائل تقریب زدن توابع است.

ارزیابی عملکرد مدل‌ها

برای ارزیابی عملکرد مدل‌های طراحی شده لازم است تا جواب‌های به دست آمده با جواب‌های مطلوب مقایسه شود. اختلاف ستاده‌های خروجی آزمون با خروجی مطلوب، خطا نامیده می‌شود. برای ارزیابی عملکرد از توابع اندازه‌گیری خطا استفاده شده است زیرا این توابع میزان انحراف را از مقدار واقعی نشان می‌دهند.

اعتبارسنجی پژوهش

به منظور اعتبارسنجی دو مدل مورد بررسی در این پژوهش به بررسی خطاهای دو مدل و ارزیابی آن‌ها پرداخته شد تا مدل مناسب‌تر را شناسایی شود. هرچه مدل برآورد شده دارای خطای کمتری در برآورد داده‌ها باشد، مدل مناسب‌تر خواهد بود و اعتبار آن بیشتر است. از همین رو در این پژوهش توابع مختلفی برای بررسی خطا این دو مدل مورد استفاده قرار گرفته تا مدل مناسب‌تر شناسایی شود. توابع مورد استفاده در این پژوهش برای ارزیابی و اعتبار مدل‌های مورد استفاده به شرح جدول (۱) می‌باشند:

جدول ۱- توابع مورد استفاده برای بررسی خطای مدل

تابع خطا	نام
$MAE = \frac{1}{n} \sum_{i=1}^n f_i - y_i = \frac{1}{n} \sum_{i=1}^n e_i $	میانگین قدر مطلق خطا
$MAPE = \frac{1}{n} \sum_{i=1}^n \left \frac{y_i - f_i}{y_i} \right \times 100$	میانگین قدر مطلق درصد خطا
$RMSE = \sqrt{E((y_i - f_i)^2)}$	ریشه میانگین مربع خطا

پیش بینی سپرده‌های سرمایه گذاری کوتاه مدت

در این بخش ابتدا به برآورد و پیش‌بینی سپرده سرمایه گذاری کوتاه مدت با استفاده از الگوی ARIMA پرداخته و سپس شبکه عصبی MLP پیش‌بینی کننده این سپرده طراحی و اجرا می گردد. همانگونه که در قبل بیان شد نخستین گام در تخمین مدل باکس جنکینز بررسی مانایی سری زمانی است. بنابراین ابتدا به کمک نرم افزار Eviews و آزمون دیکی فولر تعمیم یافته به بررسی مانایی این سری زمانی پرداخته می شود. جدول (۲) نتایج آزمون مانایی با استفاده از آزمون دیکی فولر تعمیم یافته در نرم افزار Eviews را نشان می دهد.

جدول ۲- نتایج آزمون دیکی فولر تعمیم یافته مربوط به سپرده های سرمایه گذاری کوتاه مدت

مقادیر بحرانی مک-کینان Mackinnon Critical Values			AADF	نام سری
%۱۱۰	%۵۵	%۱۱		
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	-۱/۶۹۱۹	سپرده سرمایه گذاری کوتاه مدت
-۱/۶۱۶۶	-۱/۹۴۰۹	-۲/۵۶۵۵	-۳۸/۶۹۷۸	تفاضل مرتبه اول سپرده سرمایه گذاری کوتاه مدت

همانگونه که در جدول مشاهده می شود، سری زمانی سپرده‌های سرمایه گذاری کوتاه مدت در سطح مانا نبوده و پس از یک بار تفاضل گیری در سطح ۱٪ مانا شده است. به عبارت دیگر سری زمانی dSK با اطمینان ۹۹ درصد مانا است. پس از بررسی مانایی سری زمانی سپرده‌های سرمایه گذاری کوتاه مدت گام بعدی تشخیص مرتبه‌های خودرگرسیو و میانگین متحرک مدل است که نتایج این بررسی در جدول ۳ جدول (۳) ارائه شده است.

جدول ۳- معیار آکائیک محاسبه شده مدل های مختلف ARIMA برای dSJ

۴	۳	۲	۱	۰	MA / AR
۲۶/۲۱۵۳۰	۲۶/۲۱۹۵۷	۲۶/۲۲۵۱۶	۲۶/۲۳۰۵۶	۲۶/۲۴۶۱۸	۰
۲۶/۲۱۶۰۰	۲۶/۲۱۷۱۴	۲۶/۲۱۷۵۸	۲۶/۲۱۷۱۴	۲۶/۲۳۲۹۷	۱
۲۶/۲۱۶۲۴	۲۶/۲۰۷۳۳	۲۶/۲۱۸۲۱	۲۶/۲۱۷۸۲	۲۶/۲۲۹۵۸	۲
۲۶/۲۰۶۵۸	۲۶/۲۱۰۶۹	۲۶/۲۱۰۳۲	۲۶/۲۱۷۷۰	۲۶/۲۲۴۹۵	۳
۲۶/۲۰۳۶۹	۲۶/۲۰۸۸۱	۲۶/۲۱۶۵۱	۲۶/۲۱۶۶۵	۲۶/۲۱۶۷۵	۴

همانگونه که در جدول (۳) مشاهده می‌شود، الگوی (۴و۴) ARIMA با کمترین معیار آکائیک مناسب‌ترین مدل برای تخمین و پیش‌بینی سری زمانی سپرده‌های سرمایه‌گذاری کوتاه مدت بانک سامان است. پس از برآورد مدل نهایی به بررسی مانایی پسماند مدل می‌پردازیم. جدول (۴) نشان می‌دهد که در سطح اطمینان ۹۹ درصد پسماند مدل نهایی مانا بوده و نتایج آن معتبر خواهد بود.


جدول **Error! No text of specified style in document.** - نتایج حاصل از آزمون دیکی

فولر تعمیم یافته برای آزمون ایستایی پسماند مدل

مقادیر بحرانی مک-کینان Mackinnon Critical Values			ADF	علامت اختصاری	نام سری
٪۱۰	٪۵	٪۱			
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	-۶۴/۲۶۵۲	Resid0SK	پسماند مدل سپرده سرمایه گذاری کوتاه مدت

پس از طراحی مدل ARIMA بر اساس روش باکس جنکینز در ادامه به طراحی بهترین شبکه عصبی MLP پیش‌بینی کننده سری زمانی سپرده های سرمایه گذاری کوتاه مدت بانک سامان می‌پردازیم. پس از بررسی انواع شبکه عصبی MLP بهترین مدل شبکه عصبی، شبکه عصبی MLP با الگوریتم یادگیری لیونبرگ مارکوات با ۶۵ نرون در لایه پنهان و تابع فعال سازی تانژانت هیپربولیک در این لایه تعیین شد که روند یادگیری این شبکه در شکل (۲) نشان داده شده است.

پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) /.. مهتری نمک آورانی و احتشام راثی



شکل ۲- روند یادگیری شبکه عصبی MLP پیش‌بینی کننده سپرده های سرمایه گذاری کوتاه مدت همانگونه که در شکل (۲) مشاهده می‌شود، خطای یادگیری (میانگین مربع خطاها) در این شبکه نزدیک به صفر بوده و روند یادگیری شبکه پس از شش تکرار متوقف شده است. در ادامه به منظور بررسی قدرت پیش‌بینی دو الگوی ARIMA و شبکه عصبی MLP از معیار خطای پیش‌بینی تعیین شده و ضریب تعیین (R2) استفاده می‌شود. جدول (۵) نتایج مقایسه قدرت پیش‌بینی روش ARIMA و شبکه عصبی MLP در پیش‌بینی سری زمانی سپرده‌های کوتاه مدت بانک سامان را نشان می‌دهد.

جدول ۵- مقایسه قدرت پیش‌بینی ARIMA و ANN-MLP در پیش‌بینی سپرده‌های کوتاه مدت

R2	MAPE	MAE	RMSE	الگو
۰/۹۹۹۶۱۸	۰/۰۰۲۹۸۱	۶۶۷۷۶/۲۹	۱۱۸۲۰۶	ARIMA
۰/۹۹۹۶۲۴	۰/۰۰۲۸۸۵	۵۸۸۱۹/۵۳	۱۱۷۲۶۵	ANN-MLP

همانگونه که در جدول (۵) قابل مشاهده است، شبکه عصبی MLP در کلیه معیارهای خطای پیش‌بینی قوی‌تر از الگوی ARIMA است و در مقایسه با این الگو دارای ضریب تعیین بالاتری است.

پیش‌بینی سپرده های سرمایه گذاری بلند مدت

به منظور تخمین الگوی ARIMA با روش باکس- جنکینز ابتدا به بررسی مانایی سری زمانی سپرده‌های سرمایه گذاری بلند مدت بانک سامان می‌پردازیم. جدول (۶) نتایج آزمون مانایی با استفاده از آزمون دیکی فولر تعمیم یافته در نرم افزار Eviews را نشان می‌دهد.

جدول ۶- نتایج آزمون دیکی فولر تعمیم یافته مربوط به سپرده های سرمایه گذاری بلند مدت

مقادیر بحرانی مک-کینان Mackinnon Critical Values			ADF	نام سری
٪۱۰	٪۵	٪۱		
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	۰/۲۵۶۷	سپرده بلند مدت
-۱/۶۱۶۶	-۱/۹۴۰۹	-۲/۵۶۵۵	-۷/۳۲۷۳	تفاضل مرتبه اول سپرده بلند مدت

همانگونه که در جدول (۶) مشاهده می شود، سری زمانی سپرده های سرمایه گذاری بلند مدت در سطح مانا نبوده و پس از یک بار تفاضل گیری در سطح ٪۱ مانا شده است. به عبارت دیگر سری زمانی ds5 با اطمینان ۹۹ درصد مانا است. پس از بررسی مانایی سری زمانی سپرده های سرمایه گذاری بلند مدت گام بعدی تشخیص مرتبه های خودرگرسیو و میانگین متحرک مدل است که نتایج این بررسی در جدول (۷) ارائه شده است. همانگونه که در جدول (۷) قابل مشاهده است الگوی (۴و۱) ARIMA با کمترین معیار آکائیک مناسب ترین مدل برای تخمین و پیش بینی سری زمانی سپرده های سرمایه گذاری بلند مدت بانک سامان است. پس از برآورد مدل نهایی به بررسی مانایی پسماند مدل می پردازیم. جدول (۸) نشان می دهد که در سطح اطمینان ۹۹ درصد پسماند مدل نهایی مانا بوده و نتایج آن معتبر خواهد بود. پس از طراحی مدل ARIMA بر اساس روش باکس- جنکینز در ادامه به طراحی بهترین شبکه عصبی MLP پیش بینی کننده سری زمانی سپرده های سرمایه گذاری بلند مدت بانک سامان می پردازیم. پس از بررسی انواع شبکه عصبی MLP بهترین مدل شبکه عصبی، شبکه عصبی MLP با الگوریتم یادگیری لیونبرگ مارکوات با ۶۵ نرون در لایه پنهان و تابع فعال سازی تانزانت هیپربولیک در این لایه تعیین شد که روند یادگیری این شبکه در شکل (۳) نشان داده شده است.


جدول ۷- معیار آکائیک محاسبه شده مدل های مختلف ARIMA برای ds

AR/ MA	۰	۱	۲	۳	۴
۰	۲۳/۹۲۲۰۰	۲۳/۸۸۷۹۳	۲۳/۸۷۲۲۶	۲۳/۸۶۶۸۳	۲۳/۸۵۳۰۴
۱	۲۳/۸۷۸۵۱	۲۳/۷۸۱۴۶	۲۳/۷۸۱۷۳	۲۳/۷۸۱۷۰	۲۳/۷۷۸۱۶
۲	۲۳/۸۶۰۳۰	۲۳/۷۸۱۹۹	۲۳/۷۸۲۵۳	۲۳/۷۸۲۸۷	۲۳/۷۷۸۹۲
۳	۲۳/۸۵۰۷۰	۲۳/۷۸۲۱۴	۲۳/۷۸۳۱۷	۲۳/۷۶۷۷۷	۲۳/۷۶۷۳۶
۴	۲۳/۸۳۰۶۳	۲۳/۷۷۹۳۴	۲۳/۷۷۸۸۶	۲۳/۷۶۷۶۳	۲۳/۷۶۶۹۸

پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) /.. مهتری نمک آورانی و احتشام رائی

جدول ۸- نتایج حاصل از آزمون دیکی فولر تعمیم یافته برای آزمون ایستایی پسماند مدل

مقادیر بحرانی مک-کینان Mackinnon Critical Values			ADF	علامت اختصاری	نام سری
٪۱۰	٪۵	٪۱			
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	-۶۳/۴۵۳۶	Resid0S5	پسماند مدل سپرده بلند مدت



شکل ۳- روند یادگیری شبکه عصبی MLP پیش بینی کننده سپرده های سرمایه گذاری بلند مدت همانگونه که در شکل (۳) مشاهده می شود، خطای یادگیری (میانگین مربع خطاها) در این شبکه نزدیک به صفر بوده و روند یادگیری شبکه پس از شش تکرار متوقف شده است. در ادامه به منظور بررسی قدرت پیش بینی دو الگوی ARIMA و شبکه عصبی MLP از معیار خطای پیش بینی استفاده می شود. جدول (۹) نتایج مقایسه قدرت پیش بینی روش ARIMA و شبکه عصبی MLP در پیش بینی سری زمانی سپرده های بلند مدت بانک سامان را نشان می دهد.

جدول ۹- مقایسه قدرت پیش بینی ARIMA و ANN-MLP در پیش بینی سپرده های بلند مدت

الگو	RMSE	MAE	MAPE	R2
ARIMA	۳۴۹۵۵/۴۱	۱۰۹۳۰/۷۴	۰/۰۰۰۳۲۸	۰/۹۹۹۹۸۶
ANN-MLP	۳۳۹۳۳/۱۷	۹۷۴۱/۱۱	۰/۰۰۰۲۹۳	۰/۹۹۹۹۸۷

همان گونه که در جدول (۹) قابل مشاهده است، شبکه عصبی MLP در کلیه معیارهای خطای پیش بینی قوی تر از الگوی ARIMA عمل کرده و در مقایسه با این الگو دارای ضریب تعیین بالاتری است. همان گونه که ملاحظه فرمودید در فوق به دو مورد منابع بانکها (سپرده سرمایه گذاری کوتاه مدت و بلند مدت) اشاره گردید. به منظور بررسی مانایی متغیرهای پژوهش اقدامات فوق الذکر در خصوص

فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و یکم / زمستان ۱۳۹۸

سپرده قرض الحسنه پس انداز، سپرده‌های جاری و مجموع سپرده‌های ریالی نیز صورت پذیرفته است. مانایی متغیرهای پژوهش

در این بخش مانایی متغیرها و آزمون‌های آن در داده‌های ترکیبی مورد بحث قرار می‌گیرد. مانایی متغیرهای پژوهش بدین معنی است که میانگین و واریانس متغیرها در طول زمان و کواریانس متغیرها بین سال‌های مختلف ثابت بوده است.

جدول ۱۰- نتایج آزمون دیکی فولر تعمیم‌یافته

مقادیر بحرانی مک کینان Mackinnon Critical Values			ADF	نام سری
٪۱۰	٪۵	٪۱		
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	-۱/۶۹۱۹	سپرده سرمایه‌گذاری کوتاه‌مدت
-۱/۶۱۶۶	-۱/۹۴۰۹	-۲/۵۶۵۵	-۳۸/۶۹۷۸	تفاضل مرتبه اول سپرده سرمایه‌گذاری کوتاه‌مدت
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	۰/۲۵۶۷	سپرده سرمایه‌گذاری بلندمدت
-۱/۶۱۶۶	-۱/۹۴۰۹	-۲/۵۶۵۵	-۷/۳۲۷۳	تفاضل مرتبه اول سپرده سرمایه‌گذاری بلندمدت
-۵۶۷۰/۲	-۸۶۲۰/۲	-۴۳۱۷/۳	-۸۶۵۲/۲	سپرده قرض الحسنه پس انداز
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	۰/۵۴۱۹	سپرده‌های جاری
-۱/۶۱۶۶	-۱/۹۴۰۹	-۲/۵۶۵۵	-۳۸/۵۷۸۹	تفاضل مرتبه اول سپرده‌های جاری
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	۱/۶۴۳۴	مجموع سپرده‌های ریالی
-۱/۶۱۶۶	-۱/۹۴۰۹	-۲/۵۶۵۵	-۲۱/۹۳۱۲	تفاضل مرتبه اول مجموع سپرده‌های ریالی

همان‌گونه که در جدول (۱۰) مشاهده می‌شود، سری زمانی سپرده‌های سرمایه‌گذاری کوتاه مدت، سپرده‌های سرمایه‌گذاری بلندمدت، سپرده‌های جاری و سپرده‌های ریالی در سطح مانا نبوده و پس از یک بارتفاضل گیری در سطح ٪۱ مانا شده است یا به عبارت دیگر سری زمانی سپرده‌های یاد شده با اطمینان ۹۹ درصد مانا است؛ در حالی که سری زمانی سپرده قرض الحسنه پس انداز با اطمینان ۹۵٪ در سطح مانا بوده است.

تشخیص مرتبه‌های خود رگرسیو و میانگین متحرک

پس از بررسی مانایی متغیرها به منظور طراحی مدل مناسب ARIMA ابتدا باید توابع خودهمبستگی و خودهمبستگی جزئی بررسی شود. با توجه به گفته باکس- جنکینز با استفاده از معیار آکائیک، کلیه مدل‌ها بررسی می‌گردند.

پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) /.. مهتری نمک آورانی و احتشام راثی

جدول ۱۱- معیار آکائیک محاسبه شده مدل های مختلف ARIMA

نام سری	AR/ MA	۰	۱	۲	۳	۴
سپرده سرمایه گذاری کوتاه مدت	۰	۲۶/۲۴۶۱۸	۲۶/۲۳۰۵۶	۲۶/۲۲۵۱۶	۲۶/۲۱۹۵۴	۲۶/۲۱۵۳۰
	۱	۲۶/۲۳۲۹۷	۲۶/۲۱۷۱۴	۲۶/۲۱۷۵۸	۲۶/۲۱۷۱۴	۲۶/۲۱۶۰۰
	۲	۲۶/۲۲۹۵۸	۲۶/۲۱۷۸۲	۲۶/۲۱۸۲۱	۲۶/۲۰۷۳۳	۲۶/۲۱۶۲۴
	۳	۲۶/۲۲۴۹۵	۲۶/۲۱۷۷۰	۲۶/۲۱۰۳۲	۲۶/۲۱۰۶۹	۲۶/۲۰۶۵۸
	۴	۲۶/۲۱۶۷۵	۲۶/۲۱۶۶۵	۲۶/۲۱۶۵۱	۲۶/۲۰۸۸۱	۲۶/۲۰۳۶۹
سپرده سرمایه گذاری بلندمدت	۰	۲۳/۹۲۲۰۰	۲۳/۸۸۷۹۳	۲۳/۸۷۲۲۶	۲۳/۸۶۶۶۲	۲۳/۸۵۳۰۴
	۱	۲۳/۸۷۸۵۱	۲۳/۷۸۱۴۶	۲۳/۷۸۱۷۳	۲۳/۷۸۱۷۰	۲۳/۷۷۸۱۶
	۲	۲۳/۸۶۰۳۰	۲۳/۷۸۱۹۹	۲۳/۷۸۲۵۳	۲۳/۷۸۲۸۷	۲۳/۷۷۸۹۲
	۳	۲۳/۸۵۰۷۰	۲۳/۷۸۲۱۴	۲۳/۷۸۳۱۷	۲۳/۷۶۷۷۷	۲۳/۷۶۷۳۶
	۴	۲۳/۸۳۰۶۳	۲۳/۷۷۹۳۴	۲۳/۷۷۸۸۶	۲۳/۷۶۷۶۳	۲۳/۷۶۶۹۸
سپرده قرض الحسنه پس انداز	۰	۲۷/۷۹۷۸۲	۲۶/۵۴۶۴۶	۲۵/۶۴۱۸۱	۲۵/۰۳۵۲۱	۲۴/۶۳۱۸۸
	۱	۲۳/۰۸۶۵۵	۲۳/۰۸۳۳۲	۲۳/۰۸۳۳۴	۲۳/۰۸۳۵۷	۲۳/۰۸۴۰۴
	۲	۲۳/۰۸۳۷۳	۲۳/۰۸۳۴۴	۲۳/۰۸۳۹۴	۲۳/۰۸۴۲۹	۲۳/۰۸۳۳۴
	۳	۲۳/۰۸۳۹۳	۲۳/۰۸۴۱۸	۲۳/۰۸۴۶۵	۲۳/۰۸۵۰۲	----
	۴	۲۳/۰۸۴۳۰	۲۳/۰۸۴۷۸	۲۳/۰۸۵۲۸	۲۳/۰۸۲۰۹	----
سپرده های جاری	۰	۲۷/۰۶۵۳۲	۲۷/۰۴۲۸۶	۲۷/۰۱۲۷۳	۲۷/۰۰۶۸۳	۲۷/۰۰۲۴۸
	۱	۲۷/۰۵۰۰۵	۲۷/۰۰۴۴۵	۲۷/۰۰۳۱۶	۲۷/۰۰۳۶۲	۲۷/۰۰۲۶۲
	۲	۲۷/۰۲۹۲۰	۲۷/۰۰۳۴۴	۲۷/۰۰۳۷۳	۲۷/۰۰۴۲۲	----
	۳	۲۷/۰۲۲۷۷	۲۷/۰۰۴۱۷	۲۷/۰۰۴۴۷	۲۶/۹۹۶۱۲	----
	۴	۲۷/۰۰۹۸۹	۲۷/۰۰۲۱۴	----	----	----
مجموع سپرده های ریالی	۰	۲۷/۱۶۹۲۱	۲۷/۱۵۵۰۱	۲۷/۱۵۲۲۰	۲۷/۱۵۲۱۵	۲۷/۱۴۳۸۷
	۱	۲۷/۱۵۶۸۷	۲۷/۱۴۹۷۳	۲۷/۱۵۰۱۷	۲۷/۱۵۰۵۳	۲۷/۱۴۴۶۱
	۲	۲۷/۱۵۴۰۵	۲۷/۱۵۰۴۱	۲۷/۱۵۰۸۹	۲۷/۱۵۰۹۹	۲۷/۱۴۴۲۱
	۳	۲۷/۱۵۴۶۶	۲۷/۱۵۱۰۴	۲۷/۱۵۱۰۶	۲۷/۱۴۵۷۱	۲۷/۱۴۲۴۱
	۴	۲۷/۱۴۳۸۴	۲۷/۱۴۳۳۶	۲۷/۱۴۲۷۴	۲۷/۱۴۲۵۰	----

همانگونه که در جدول فوق مشاهده می‌شود، الگوی (۴،۱،۴) ARIMA با کمترین معیار آکائیک مناسب‌ترین مدل برای تخمین و پیش‌بینی سری زمانی سپرده‌های سرمایه‌گذاری کوتاه‌مدت، الگوی (۴،۱،۴) ARIMA با کمترین معیار آکائیک مناسب‌ترین مدل برای تخمین و پیش‌بینی سری زمانی سپرده‌های سرمایه‌گذاری بلندمدت، الگوی (۴،۰،۳) ARIMA با کمترین معیار آکائیک مناسب‌ترین مدل برای تخمین و پیش‌بینی سری زمانی سپرده‌های قرض‌الحسنه پس‌انداز، الگوی (۳،۱،۳) ARIMA با کمترین معیار آکائیک مناسب‌ترین مدل برای تخمین و پیش‌بینی سری زمانی سپرده‌های جاری و درنهایت الگوی (۳،۱،۴) ARIMA با کمترین معیار آکائیک مناسب‌ترین مدل برای تخمین و پیش‌بینی سری زمانی مجموع سپرده‌های ریالی بانک سامان است.

مانایی پسماند مدل‌ها

برای انجام مانایی پسماند مدل‌ها نیز از آزمون دیکی فولر تعمیم یافته استفاده گردید.

جدول ۱۲- نتایج آزمون دیکی فولر تعمیم یافته برای آزمون مانایی پسماند مدل

مقادیر بحرانی مک کینان Mackinnon Critical Values			ADF	نام سری
%۱۰	%۵	%۱		
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	-۶۴/۲۶۵۲	پسماند مدل سپرده سرمایه‌گذاری کوتاه-مدت
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	-۶۳/۴۵۳۶	پسماند مدل سپرده سرمایه‌گذاری بلند-مدت
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	-۶۳/۵۹۰۹	پسماند مدل سپرده قرض‌الحسنه پس‌انداز
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	-۶۳/۴۴۲۸	پسماند مدل سپرده‌های جاری
-۳/۱۲۷۲	-۳/۴۱۰۹	-۳/۹۶۰۳	-۳۴/۵۴۷۱	پسماند مدل مجموع سپرده‌های ریالی

در جدول (۱۴) به منظور بررسی قدرت پیش‌بینی دو الگوی ARIMA و شبکه عصبی MLP، از معیار خطای پیش‌بینی تعیین شده و ضریب تعیین (R^2) استفاده می‌شود.

پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) /.. مهری نمک آورانی و احتشام راثی

جدول ۱۴- مقایسه قدرت پیش بینی ARIMA و ANN-MLP

نام سپرده	الگو	RMSE	MAE	MAPE	R ²
سپرده های سرمایه گذاری کوتاه مدت	ARIMA	۱۱۸۲۰۶	۶۰۷۷۶/۲۹	۰/۰۰۲۹۸۱	۰/۹۹۹۶۱۸
	ANN-MLP	۱۱۷۲۶۵	۵۸۸۱۹/۵۳	۰/۰۰۲۸۸۵	۰/۹۹۹۶۲۴
سپرده های سرمایه گذاری بلندمدت	ARIMA	۳۴۹۵۵/۴۱	۱۰۹۰۳/۷۴	۰/۰۰۰۳۲۸	۰/۹۹۹۹۸۶
	ANN-MLP	۳۳۹۳۳/۱۷	۹۷۴۱/۱۱	۰/۰۰۰۲۹۳	۰/۹۹۹۹۸۷
سپرده های قرض الحسنه پس انداز	ARIMA	۲۴۸۲۵/۷۱	۴۳۹۷/۸۰۲	۹۰/۰۰۳۱	۰/۹۹۱۰۸۶
	ANN-MLP	۲۴۲۵۴/۹۵	۴۳۸۴/۶۱۸	۸۰/۰۰۳۱	۰/۹۹۱۴۹۲
سپرده های جاری	ARIMA	۱۷۸۴۷۸/۴	۳۲/۸۹۰۵۸	۰/۰۰۵۸۶	۰/۹۹۵۱۷
	ANN-MLP	۱۷۵۷۸۵/۷	۸۷۳۳۸/۵۹	۰/۰۰۵۷۴	۰/۹۹۵۳۱
مجموع سپرده های ریالی	ARIMA	۱۸۹۰۷۹/۵	۹۶۵۱۹/۴	۰/۰۰۱۳۴۷	۰/۹۹۹۹۰۴
	ANN-MLP	۱۸۶۴۱۱/۸	۹۲۹۱۴/۸	۰/۰۰۱۲۹۷	۰/۹۹۹۹۰۶

با توجه به نتایج مندرج در جدول فوق روش های شبکه عصبی پرسپترون چند لایه در پیش بینی میزان سپرده های بانک سامان، از لحاظ شاخص خطای ریشه میانگین مربع خطا، شاخص میانگین قدر مطلق خطا، شاخص میانگین قدر مطلق درصد خطا و شاخص ضریب تعیین از روش ARIMA برتر است.

نتیجه گیری

در این پژوهش با توجه به سوالات و فرضیات مطرح شده، به پیش بینی انواع سپرده های بانک سامان با استفاده از روش ARIMA و روش شبکه عصبی پرداخته شد. نتایج برآورد و پیش بینی انواع سپرده ها نه تنها موید قدرت بالاتر و برتری شبکه عصبی بر الگوی ARIMA از نظر معیار ضریب تعیین است، بلکه از نظر معیارهای ارزیابی پیش بینی شبکه عصبی بهتر از الگوی ARIMA بوده است. بررسی نتایج و جداول ارائه شده نشان می دهد که شبکه عصبی از نظر معیارهای ریشه میانگین مربع خطا، شاخص میانگین قدر مطلق خطا، شاخص میانگین قدر مطلق درصد خطا نیز بهتر از الگوی ARIMA عمل کرده است.

در مجموع نتایج این مطالعه و تحقیقات فوق، نشان می‌دهد شبکه عصبی مصنوعی در پیش‌بینی سری‌های زمانی مالی از جمله سپرده‌های بانک سامان قدرت بالایی داشته و از این رو به منظور سیاست‌گذاری و برنامه‌ریزی در امور مالی که لازمه‌ی آن پیش‌بینی مقادیر آتی انواع سپرده‌های بانک است می‌توان از شبکه عصبی MLP با اطمینان بیشتری استفاده کرد.

با توجه به اینکه بانک سامان بر اساس برنامه‌های خود در بحث جذب سپرده، برای کل مجموعه و هر یک از شعب خود اهدافی را تعیین می‌کند و عملکرد مجموعه را بر اساس اهداف تعیین شده می‌سنجد، می‌توان بر اساس مدل‌های حاصل شده از نتایج این پژوهش در پیش‌بینی میزان سپرده‌ها و تعیین اهداف استفاده و در تعدیل و افزایش اهداف تعیین شده و برنامه‌ریزی جهت تخصیص منابع از آن استفاده کرد. بر اساس نتایج و مطالب این مطالعه و همچنین بررسی تحقیقات گذشته، پیشنهادات زیر در خصوص پژوهش‌ها و تحقیقات آتی ارائه می‌شود:

۱. در این پژوهش تنها از اطلاعات هر یک از سپرده‌ها در گذشته به عنوان عامل پیش‌بینی کننده آن‌ها در آینده استفاده شد. در صورتی که می‌توان با وارد کردن شاخص‌های مفهومی دیگر نیز برای پیش‌بینی میزان سپرده‌ها استفاده کرد.

۲. همانگونه که در این مطالعه نشان داده شد، بهترین الگوریتم یادگیری برای آموزش شبکه جهت پیش‌بینی سری زمانی سپرده‌های بانک سامان که نماینده‌ای از سری‌های زمانی مالی می‌تواند باشد، الگوریتم یادگیری لونیبرگ-مارکوارت است. با این وجود می‌توان جهت آموزش شبکه از الگوریتم‌های تکاملی از جمله الگوریتم ژنتیک و انبوه ذرات در مطالعات آتی به منظور آموزش هر چه بهتر شبکه و دستیابی به نتایج مطلوب‌تر بهره برد.

منابع

- ۱) احتشام راثی رضا، احسانی فر محمد. (۱۳۹۴)، پیش بینی نرخ ارز در بازار سرمایه با استفاده از مدل های میانگین متحرک خود رگرسیون انباشته و شبکه عصبی (مطالعه موردی: دلار استرالیا، دلار کانادا، ین ژاپن و پوند انگلیس)، دانش مالی تحلیل اوراق بهادار، شماره ۲۷، صص ۳۵-۵۲.
 - ۲) احمدی شالی جعفر، وصفی مهدی. (۱۳۹۶). پیش بینی نقدینگی بر اساس برآورد نقطه ای و بازه ای روش آریمای و مقایسه آن با روش هموارسازی نمایی دوگانه. فصلنامه اقتصاد مالی، شماره ۴۰، صص ۱۷۵-۱۵۹.
 - ۳) البرزی، محمود. (۱۳۸۰). آشنایی با شبکه های عصبی، انتشارات علمی دانشگاه صنعتی شریف.
 - ۴) بمانی عاطفه، هروی علی؛ نقیبه سپیده، زنده دل احمد، شهنساری سوده. (۱۳۹۴). پیش بینی قیمت سهام بانک های پذیرفته شده در بورس اوراق بهادار تهران بر اساس مدل PCA-NN مقایسه آن با مدل آریمای، دومین کنفرانس بین المللی آینده پژوهی، مدیریت و توسعه اقتصادی، دانشگاه تربیت مدرس، مشهد، ایران.
 - ۵) حسینی پور سید محمدرضا، محسنی سیمین، جعفری مقدم مسعود. (۱۳۹۷). مقایسه سه روش برنامه ریزی خطی، آرمانی و فازی در ترکیب بهینه منابع و مصارف در بانک کشاورزی، مهندسی مالی و مدیریت اوراق بهادار، شماره ۳۷، صص ۳۷۴-۳۵۴.
 - ۶) زارعی قاسم، محمدیان رعنا، حاضری هاتف، باشکوه اجیرلو محمد. (۱۳۹۷). مقایسه روش های شبکه عصبی فازی با شبکه عصبی موجک فازی در پیش بینی قیمت سهام بانک های پذیرفته شده در بورس اوراق بهادار تهران، راهبرد مدیریت مالی، شماره ۲۲، صص ۱۳۸-۱۰۹.
 - ۷) عباسی، ابراهیم، رستگاری، فاطمه، ابراهیمی، فهیمه. (۱۳۹۳). پیش بینی نقدینگی مورد نیاز دستگاه های خودپرداز با استفاده از مدل خطی (ARIMA) و غیرخطی (شبکه های عصبی). فصلنامه سیاست های راهبردی و کلان، شماره ۸، دوره ۲، صص ۷۶-۵۹.
 - ۸) عاملی احمد، رضانی ملیحه. (۱۳۹۴). پیش بینی قیمت سهام با استفاده از شبکه عصبی فازی مبتنی بر الگوریتم ژنتیک و مقایسه با شبکه عصبی فازی، تحقیقات مدل سازی اقتصادی، شماره ۲۲، صص ۹۱-۶۱.
 - ۹) محمدی شاپور، راعی رضا، رحیمی محمدرضا. (۱۳۹۷). پیش بینی دامنه تغییرات طلا با استفاده از مدل ترکیبی ARIMA و شبکه عصبی، مهندسی مالی و مدیریت اوراق بهادار، شماره ۳۴، صص ۳۳۵-۳۵۷.
 - ۱۰) منهای، محمد باقر. (۱۳۸۷). مبانی شبکه های عصبی، انتشارات دانشگاه صنعتی امیر کبیر.
- 11) Ayodele A. Adebisi, Aderemi O. Adewumi (2014). Stock Price Prediction Using the ARIMA Model, School of Mathematic, Statistics & Computer Science, 16th International Conference on Computer Modelling and Simulation, pp.105-111.

- 12) Aydinm, A. D. & Cavdar, S.C. (2015). Prediction of Financial Crisis with Artificial Neural Network: An Empirical Analysis on Turkey. *International Journal of Financial*, 6(4): 36-45
- 13) Basak, S. Kar, S. Saha, S. & Khaidem, L. (2018). Predicting the direction of stock market prices using tree-based Classifiers. *North American Journal of Economics and Finance*. (in press).
- 14) Bokota, A. (2002). Principle of forecasting in manufacturing Companies. *WTO Yearly Report*, USA.
- 15) Bruno M. H. Vinicius A. S. and Herbet K. (2018). Stock price prediction using support vector regression on daily and up to the minute prices, *The Journal of Finance and Data Science*, in press. pp.1-5.
- 16) Jadhav, S. Dange, B. & Shikalgar, S. (2018). Prediction of Stock Market Indices by Artificial Neural Networks Using Forecasting Algorithms. In *International Conference on Intelligent Computing and Applications* (pp. 455-464).
- 17) Nguyen, T., Khosravi, A., Nahavandi, S., & Creighton, D. (2013). Neural Network and Interval Type-2 Fuzzy System for Stock Price Forecasting. *International Conference on Fuzzy Systems (FUZZ-IEEE)*.
- 18) Thu Phan Hien, Anwar Sajid, W. Robert J. Alexander, Thi My Phan Hanh. (2019). Competition, Efficiency and Stability: An Empirical Study of East Asian Commercial Banks, *North American Journal of Economics & Finance*, 18: 1-41.
- 19) Yuhong Li, Weihua Ma. (2010). Applications of Artificial Neural Networks in Financial Economics: A Survey. *Computational Intelligence and Design (ISCID)*, 1,211-214.
- 20) Refenes, A. N., Zapranis, A. & Gavin, F. (1997). Modeling Stock Returns in the Framework of APT C Comparative Study with Regressing Models. In A. P. (Ed) *Neural Network in the Capital Markets*, 7(2):374-388.
- 21) Zhang, J., Cui, S. Xu, Y. Li, Q. & Li, T. (2018). A novel data-driven stock price trend prediction system. *Expert Systems with Applications* 97, pp. 60–69.

-
- 1 .Thu Phan et al
 - 2 . Box-Jenkins
 - 3 . Bokota
 - 4 . Refenes et al
 - 5 . Zhang et al
 - 6 . Basak et al
 - 7 . Ayodele et al
 - 8 . Autoregressive Moving Average Model
 - 9 . non-stationary
 - 10 . Moving Average
 - 11 . Autoregressive
 - 12 . Artificial Neural Network - ANN
 - 13 . Multilayer Perceptron(MLP)
 - 14 . Mapping
 - 15 . Hidden Layer
 - 16 . Kolmogorov Theorem
 - 17 . Jadhav et al
 - 18 . Bruno et al
 - 19 . Aydinm & Cavdar
 - 20 . Nguyen et al
 - 21 . Feed Forward Neural Network
 - 22 . Interval Type-2 Fuzzy Logic System
 - 23 . Yuhong & Weihua
 - 24 . Integrated Average