

مدل ترکیبی شبکه‌های عصبی مصنوعی پیش‌خور و خودسازمانده کوهونن برای پیش‌بینی قیمت سهام

دکتر پیام حنفی‌زاده*
ابوالفضل جعفری**

چکیده

این مقاله ضمن ارائه مدلی ترکیبی از شبکه‌های عصبی مصنوعی، به بررسی توان پیش‌بینی‌کنندگی آنها در مقایسه با مدل‌های منفرد می‌پردازد. در این بررسی، با استفاده از شبکه‌های عصبی ترکیبی متشکل از شبکه‌های پیش‌خور و خودسازمانده کوهونن اقدام به پیش‌بینی قیمت سهام شده است. نتایج آزمایشات محاسباتی در پیش‌بینی قیمت سهام در بازار بورس تهران نشان می‌دهد که ترکیب شبکه خودسازمانده کوهونن با شبکه پیش‌خور، در مقایسه با مدل منفرد شبکه پیش‌خور که پرکاربردترین مدل شبکه‌های عصبی مصنوعی در حوزه پیش‌بینی است، عملکرد بهتری در پیش‌بینی قیمت سهام ارائه می‌کند.

* استادیار گروه مدیریت صنعتی، دانشگاه علامه طباطبایی E.Mail: hanafizadeh@gmail.com

** دانشجوی دکترای مدیریت مالی، دانشگاه علامه طباطبایی

واژگان کلیدی: پیش‌بینی، قیمت سهام، شبکه‌های عصبی خودسازمانده، شبکه‌های عصبی پیش‌خور

مقدمه

پیش‌بینی در بازارهای سرمایه همواره با چالش، تردید و خطا مواجه بوده است و روش‌های مورد استفاده دارای نقاط ضعفی هستند که کاربرد آنها را با محدودیت مواجه می‌سازد [۴]. سیستم‌های هوشمند یکی از فناوری‌های نوین این عصر است که با استفاده از آنها می‌توان سعی در طراحی مدل‌هایی برای پیش‌بینی در بازارهای سرمایه (برای مثال پیش‌بینی قیمت سهام) نمود.

هر پدیده‌ای که ماهیت پویایی داشته باشد و از حالت ایستا دورتر باشد، پیش‌بینی آن در آینده دشوارتر می‌شود. از جمله این حوزه‌های پویا و شاید تاحدودی آشوب گونه، بازارهای سهام می‌باشند [۴]. کسب سود در این بازار در گرو خرید و فروش به موقع سهام است. به همین منظور زمان مناسب جهت خرید و فروش از مهم‌ترین پرسشهایی است که ممکن است برای هر سهامدار یا سرمایه‌گذار در بازار بورس به وجود آید و برای دانستن زمان مناسب، انتظار می‌رود که بتوان قیمت سهام را به درستی پیش‌بینی کرد. در این راستا، تحقیقات بسیاری انجام پذیرفته است و تلاش شده با استفاده از ابزارهای ریاضی و آمار، سری‌های زمانی طولانی مدت، قیمت سهام تحلیل و الگوی رفتاری آنها شناسایی شوند [۱]. از جمله این تحقیقات می‌توان به مطالعات انجام گرفته توسط رجب‌زاده قطری (۱۳۷۷)، حاتمی (۱۳۸۰) و هادی‌پور (۱۳۸۲) در ایران، بارکالوس، باوم و تراولس^۱ (۱۹۹۷) و اوومن^۲ (۲۰۰۱) در خارج اشاره کرد. اما امکان کشف این الگوها یا ساختارهای ویژه تاحدود زیادی به ماهیت فرایند مولد قیمت سهام بستگی دارد. این فرایند می‌تواند به سه طبقه ۱- خطی، ۲- تصادفی، ۳- آشوب گونه (غیرخطی) دسته‌بندی شود. بر این اساس قابلیت پیش‌بینی در فرایندهای خطی ممکن، در فرایندهای تصادفی غیرممکن و در فرایندهای آشوب گونه تا حدی ممکن است [۶]. در مورد تصادفی بودن رفتار قیمت

1- Barkoulas, Baum & Travlos

2- Oomen

سهام، تحقیقاتی که طی سالهای ۱۳۷۳ و ۱۳۷۴ در زمینه کارایی بازار بورس تهران توسط فدایی‌نژاد و نمازی انجام شده است نشان می‌دهند که تغییرات متوالی قیمت سهام در بورس تهران به صورت مستقل و تصادفی نبوده، بلکه روند و الگوی خاصی در رفتار قیمت‌ها مشاهده می‌شود [۱۲، ۱۵].

از سوی دیگر تحقیقات انجام شده نشان می‌دهند که بازار سهام، رفتاری غیرخطی و آشوب‌گونه دارد. بدین مفهوم که رفتار ایستا نبوده و حرکتی پویا را نشان می‌دهد، لذا مدل‌های خطی و استاتیک قادر به تبیین رفتار چنین سیستم‌هایی نیستند [۶، ۷]. بنابراین برای کشف روابط بین آنها نیاز به ابزارها و مدل‌های غیرخطی است. یکی از این مدل‌های غیرخطی پرکاربرد شبکه‌های عصبی مصنوعی^۱ هستند. یکی از مهم‌ترین جذابیت‌های شبکه‌های عصبی، انعطاف آنها در تخمین دامنه وسیعی از روابط و توابع بین مقادیر داده‌ها و ستاده‌ها است [۵]. این شبکه‌ها در مقایسه با روش‌های سنتی ثابت کرده‌اند که در کشف این نوع روابط عملکرد بهتری دارند [۱۹، ۳۴]. علاوه بر این، به دلیل درجه بالای اغتشاش^۲ در داده‌های مالی، روش‌های غیرمنعطف سنتی نمی‌توانند به خوبی شرایط را برآورده کنند، اما شبکه‌های عصبی مصنوعی نشان داده‌اند که می‌توانند به خوبی از پس این اغتشاش داده‌ها برآیند [۲۸]. همچنین باید خاطر نشان کرد که سری‌های زمانی اغلب دارای داده‌های مفقود^۳ می‌باشند. شبکه‌های عصبی مصنوعی در مقایسه با روش‌های خطی در مواجهه با این واقعیت نیز عملکرد بهتری ارائه می‌کنند [۳۴].

با این حال، اکثر تحقیقاتی که در زمینه پیش‌بینی قیمت سهام انجام گرفته‌اند، ماهیت غیرایستای^۴ سری‌های زمانی قیمت سهام را نادیده گرفته‌اند. غیر ایستا بودن ماهیت سری‌های زمانی قیمت سهام بدین معنا است که توزیع‌های آماری سری‌های قیمت سهام در طول زمان تغییر می‌کنند. چنین تغییرات ساختاری که اغلب به واسطه رویدادهای سیاسی، شرایط اقتصادی، انتظارات داد و ستدکنندگان اوراق بهادار و سایر عوامل محیطی به وجود می‌آیند یکی از ویژگی‌های مهم سری‌های قیمت سهام

1- Artificial Neural Networks (ANNs)

2- noise

3- missing data

4- non-stationary

می‌باشد. این نوسان‌پذیری، تبیین و ویژگی غیر ایستا بودن داده‌های مزبور را برای مدل‌های منفرد شبکه‌های عصبی مصنوعی دشوار می‌سازد. یکی از راه‌حل‌های بالقوه برای حل این مسئله، ترکیب مدل‌های مختلف شبکه‌های عصبی مصنوعی است [۲۵]. در راستای این هدف، می‌توان از مدل ترکیبی شبکه‌های خودسازمانده

کوهونن و شبکه‌های پیش‌خور برای پیش‌بینی بهتر قیمت سهام استفاده کرد.

ترکیب شبکه‌های خودسازمانده کوهونن با شبکه‌های پیش‌خور علاوه بر حل مسئله غیر ایستا بودن ماهیت سری‌های قیمت سهام، مزایای دیگری نیز دارد. شبکه‌های عصبی پیش‌خور وقتی که به صورت منفرد به کار گرفته می‌شوند از ثبات خوبی برخوردار نمی‌باشند، اما توانایی بالایی در شناسایی و تشخیص روابط بین متغیرها دارند. از سوی دیگر شبکه‌های خودسازمانده کوهونن با وجود اینکه از ثبات خوبی برخوردارند، به تنهایی قادر به تشخیص تعداد نامحدود الگوها نمی‌باشند. ترکیب شبکه‌های عصبی پیش‌خور و خودسازمانده کوهونن مزیت ثبات شبکه کوهونن را با توانایی شبکه پیش‌خور در تشخیص تعداد نامحدود الگوها ترکیب می‌کند. ضمن اینکه شبکه خودسازمانده کوهونن در برخی موارد می‌تواند الگوهایی را تشخیص دهد که شبکه پیش‌خور قادر به شناسایی آنها نمی‌باشد، این مزیت نیز در شبکه عصبی ترکیبی حفظ می‌شود. از اینرو، در این مقاله با طراحی نوعی شبکه عصبی ترکیبی متشکل از شبکه‌های پیش‌خور و خودسازمانده کوهونن، قدرت پیش‌بینی‌کنندگی شبکه‌های عصبی بهبود یافته و عملکرد شبکه عصبی ترکیبی در پیش‌بینی قیمت سهام در بازار بورس تهران با شبکه‌های غیر ترکیبی (منفرد) مورد مقایسه قرار می‌گیرد. در راستای انجام این مهم از نقاط قوت و دستاوردهای تحقیقات پیشین استفاده شده است.

علاوه بر بخش مقدمه، این مقاله در چهار بخش دیگر سازمان یافته است. در بخش دوم، مروری بر ادبیات شبکه‌های عصبی انجام گرفته و پیش‌زمینه‌ای از کاربرد آنها در پیش‌بینی متغیرهای مالی و اقتصادی ارائه شده است. بخش سوم به توصیف روش ساخت، آموزش و آزمایش مدل شبکه عصبی پیشنهادی می‌پردازد. کارایی

عملکرد این مدل و توان پیش‌بینی‌کنندگی آن، در بخش چهارم مورد بررسی قرار گرفته است. جمع‌بندی و نتیجه‌گیری نیز در بخش پنجم ارائه شده است.

مروری بر ادبیات و پیشینه تحقیق

امروزه شبکه‌های عصبی مصنوعی جایگاه مهمی در ادبیات پیش‌بینی متغیرهای اقتصادی به خود اختصاص داده‌اند. مهم‌ترین مزیت این مدل نسبت به سایر مدل‌های ساختاری و سری زمانی آن است که در طراحی این مدل‌ها، نیازی به اعمال فرض‌های آماری خاص در مورد رفتار متغیرها مانند فرض‌های مربوط به تابع توزیع احتمال و یا اعمال فرض‌های مربوط به نحوه ارتباط بین متغیرها نیست. البته همین نقطه قوت مدل‌های شبکه عصبی یعنی آزادی آنها از قيود مفروضات مدل‌های آماری، از نظر برخی از اقتصاددانان، نقطه ضعف آنها نیز به شمار می‌رود. زیرا از نظر آنها اگر نتوان نتایج حاصل از این مدل‌ها را از لحاظ آماری ارزیابی کرد، به عنوان مثال سطح اعتماد مقادیر پیش‌بینی شده را مشخص نمود، نمی‌توان از آنها نتایج آماری معتبری را استنتاج کرد. اما وایت^۱ (۱۹۹۴) تا حدودی موفق شد ویژگی‌های آماری این مدل‌ها و انطباق آنها را با مفاهیم رگرسیون نشان دهد [۱۴].

از آنجایی که برای مدل‌سازی و پیش‌بینی با این مدل‌ها به داده‌های فراوان نیاز است و متغیرهای مالی دارای طولانی‌ترین سری‌های زمانی در اقتصاد هستند و همچنین معمولاً توزیع‌های احتمال مربوط به متغیرهای مالی از توزیع‌های احتمال استاندارد و شناخته شده‌ای تبعیت نمی‌کنند، متغیرهای مالی یکی از وسیع‌ترین زمینه‌های کاربردی این مدل‌ها در پیش‌بینی هستند [۱۴].

مروری بر پیشینه تحقیق نشان می‌دهد که به‌طور کلی از نظر الگوریتم یادگیری^۲ و آموزش شبکه، آموزش با ناظر^۳ به همراه الگوریتم یادگیری پس انتشار خطا^۴ بیشترین کاربرد را در حوزه مالی داشته و عملکرد خوبی را نیز از خود نشان داده است [۱۹، ۲۶، ۳۲ و ۳۹]. این امر ناشی از این حقیقت است که در حوزه مزبور

1-White

2- learning algorithm

3- supervised learning

4- error back-propagation

پیش‌بینی قیمت دارایی به عنوان خروجی هدف در نظر گرفته می‌شود و ورودی‌هایی وجود دارند که در پیش‌بینی قیمت، همبستگی‌های غیرخطی دارند. از نظر معماری (توپولوژی) شبکه نیز به‌طور کلی، شبکه‌های پیش‌خور^۱ بیشترین کاربرد را داشته‌اند، اما این‌گونه نبوده است که همواره به صورت مجزا به کار رفته باشند. یکی از دستاوردهای تحقیق حاضر، تهیه جدول مقایسه‌ای از تحقیقات انجام شده در پیشینه تحقیق است. جدول ۱، خلاصه مطالعات انجام گرفته را بر اساس پارامترهای معینی مانند هدف تحقیق، معماری شبکه، الگوریتم یادگیری، تابع فعال‌سازی^۲، معیار دقت پیش‌بینی و تعداد لایه‌های پنهان^۳ استفاده شده در ساختار شبکه عصبی نشان می‌دهد. جدول مزبور نشان می‌دهد که در اکثر مدل‌های شبکه عصبی مورد استفاده در تحقیقاتی که به منظور پیش‌بینی در حوزه مالی و سرمایه‌گذاری انجام گرفته‌اند، از نوع شبکه پیش‌خور با الگوریتم یادگیری پس انتشار خطا و یک لایه پنهان، تابع سیگموئید به عنوان تابع فعال‌سازی و میانگین مجذور خطا (MSE) به عنوان معیار دقت پیش‌بینی استفاده شده است. کلیه تحقیقاتی که در این جدول خلاصه شده‌اند، تحقیقاتی هستند که با استفاده از تنها یک نوع شبکه عصبی انجام گرفته‌اند.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

1- feedforward
2- activation function
3- hidden layer

جدول ۱. خلاصه مطالعات انجام شده در پیشینه تحقیق

ویژگی پژوهشگر	هدف تحقیق	معماری شبکه	الگوریتم یادگیری	تابع فعال‌سازی (انتقال)	معیار دقت پیش‌بینی	تعداد لایه‌های پنهان
تانگ و همکاران (۱۹۹۱)	پیش‌بینی سریهای زمانی		پس انتشار خطا	سیگموئید ^۱	MSE	۱
تریپی و دیزینو (۱۹۹۲)	پیش‌بینی عملکرد سهام	پیش‌خور	پس انتشار خطا			۴
ریفنس و همکاران (۱۹۹۳)	دسته‌بندی سهام		پس انتشار خطا	سیگموئید	RMSE	۱
کالونیک و رادفر (۱۹۹۴)	پیش‌بینی قیمت پایانی روزانه شرکت IBM و تعداد مسافران شرکت هواپیمایی	پیش‌خور	پس انتشار خطا	سیگموئید	MSE	۱
کانر و همکاران (۱۹۹۴)	پیش‌بینی سریهای زمانی	شبکه بازگشتی	پس انتشار خطا	سیگموئید	MSE	۱
وارمر و میسرا (۱۹۹۶)	حل مسائل پیش‌بینی و دسته‌بندی	پرسپترون چندلایه	پس انتشار خطا	سیگموئید	SSE	۱

1- sigmoid
 2- mean square error
 3- root mean square error
 4- sum of square error

تعداد لایه‌های پنهان	معیار دقت پیش بینی	تابع فعال‌سازی (انتقال)	الگوریتم یادگیری	معماری شبکه	هدف تحقیق	ویژگی پژوهشگر
۱	SSE	تانژانت-سیگموئید	پس انتشار خطا	پرسپترون چندلایه	پیش‌بینی ارزش اسناد بانکی جدید انتشار	رورخامت و همکاران (۱۹۹۸)
۱	MSE	لگ‌سیگموئید	پس انتشار خطا	پرسپترون چندلایه	پیش‌بینی بازده شاخص‌های بورس‌های اصلی سهام در دنیا	شاچموروف و ویتکفسکا (۲۰۰۰)
۱	MSE	سیگموئید	پس انتشار خطا	پرسپترون چندلایه	پیش‌بینی علائم تغییر قیمت سهام	کستیگیلونه (۲۰۰۰)
۱	MAE و RMSE	سیگموئید	پس انتشار خطا	پیش‌خور	پیش‌بینی قیمت قراردادهای آتی روی شاخص S&P	شیخ حمید (۲۰۰۴)
۱	MSE	سیگموئید	پس انتشار خطا	پیش‌خور	پیش‌بینی علائم خرید و فروش سهام	ژانگ و همکاران (۲۰۰۴)
۱	MSE	سیگموئید	پس انتشار خطا	پیش‌خور	پیش‌بینی بازده شاخص سهام بورس اوراق بهادار بمبئی	پاندا و ناراسیمهان (۲۰۰۶)

1- mean absolute error

اما تحقیقات اخیر به سمت ترکیب روش‌های مختلف هوش مصنوعی حرکت کرده است [۲۲]. با ترکیب مدل‌های مختلف شبکه‌های عصبی مصنوعی با یکدیگر، امکان استفاده از نقاط قوت مدل‌های مختلف فراهم می‌گردد و نقاط ضعف مدل‌های منفرد پوشش داده می‌شود. شبکه‌های عصبی مدل‌های مختلفی دارند از این رو، با استفاده از انواع مدل‌های شبکه عصبی، مدل‌های ترکیبی مختلفی را می‌توان طراحی کرد. یکی از انواع مدل‌های ترکیبی قابل طراحی شبکه‌های عصبی، مدل شبکه عصبی ترکیبی متشکل از شبکه‌های پیشرو (پرسپترون چندلایه)^۱ و شبکه‌های خودسازمانده کوهونن است. ترکیب این دو نوع شبکه در واقع ترکیب دو نوع شبکه با ناظر^۲ و بدون ناظر^۳ است.

منطق زیربنای استفاده از شبکه پیشرو (پرسپترون چندلایه) در ساختار شبکه ترکیبی این است که شبکه مزبور ویژگی‌های برداری موجود در مجموعه داده‌ها را تشخیص می‌دهد و آنها را بر آن اساس طبقه‌بندی می‌کند. این ویژگی، خاصیت تقریب‌زننده جهانی^۴ را که به وسیله نظریه وجود کولموگروف^۵ به شرح ذیل بیان می‌شود، بهبود می‌بخشد [۱۷]:

شبکه عصبی پیشرو با سه لایه از نرون‌ها (لایه ورودی، لایه پنهان و لایه خروجی) می‌تواند هر نوع تابع پیوسته‌ای را به دقت تقریب بزند [۲۲].

منطق زیربنای استفاده از شبکه خودسازمانده کوهونن در ساختار شبکه ترکیبی، تجزیه داده‌ها به تعدادی طبقه معین است که امر تشخیص و طبقه‌بندی را بهبود می‌بخشد. طبقه‌بندی داده‌ها فرایندی است که طی آن، داده‌هایی که دارای ویژگی‌های مشابهی هستند در قالب گروه‌های معین طبقه‌بندی می‌شوند. طبقات داده‌ها با استفاده از معیارهای سنجش فاصله شکل می‌گیرند. از این رو، هر طبقه به عنوان گروهی از الگوهای مشابه مورد شناسایی قرار می‌گیرد [۱۷]. به عبارت دیگر شبکه خودسازمانده کوهونن، کل فضای ورودی را به فضاهایی تجزیه می‌کند که در آنها داده‌های دارای توزیع‌های آماری مشابه، در یک گروه قرار می‌گیرند و از این طریق

1- multilayer perceptron

2- supervised

3- unsupervised

4- universal approximator property

5- Kolmogorov's existence theorem

امکان تبیین ویژگی غیرایستا بودن داده‌های مالی فراهم می‌گردد [۲۵]. پس از تجزیه داده‌های ورودی ناهمگون به فضاهاى مختلف همگون، شبکه پیش‌خور می‌تواند قیمت سهام را بهتر پیش‌بینی کند. از سوی دیگر، استفاده از شبکه کوهون بدون ناظر در ساختار شبکه ترکیبی، امکان تبیین رفتار سری‌های داده‌های ریزبافت^۱ در شبکه پیش‌رو را به وجود می‌آورد [۲۶].

تاکنون چند تحقیق در سطح دنیا در زمینه استفاده از مدل‌های ترکیبی شبکه‌های عصبی پیش‌خور و خودسازمانده کوهون برای پیش‌بینی قیمت سهام انجام گرفته است. هوئی و همکارانش (۲۰۰۰) با استفاده از مدل‌های ترکیبی شبکه‌های عصبی پرسپترون چندلایه (با الگوریتم یادگیری پس انتشار خطا) و شبکه‌های خودسازمانده کوهون اقدام به پیش‌بینی قیمت سهام در بورس اوراق بهادار کوالا لامپور (KLSE) نمودند. شبکه کوهون در لایه اولیه مدل ترکیبی برای فیلتر کردن داده‌های ورودی به الگوهای مشخص و در نتیجه ساده‌سازی آموزش شبکه پرسپترون چندلایه مورد استفاده قرار گرفته است. از شبکه پرسپترون چندلایه نیز در ساختار مدل ترکیبی برای پردازش داده‌های خروجی شبکه کوهون استفاده شده است. یافته‌های این تحقیق حاکی از آن است که عملکرد مدل ترکیبی شبکه عصبی در پیش‌بینی قیمت سهام در بورس اوراق بهادار کوالا لامپور از هر دو منظر کیفیت و دقت بهتر از هر دو مدل مورد استفاده در ساختار آن بوده است. شبکه مزبور عملکرد با ثباتی ارائه کرده است که تحت تأثیر ماهیت آشوب گونه داده‌های ورودی قرار نگرفته است. به زعم هوئی و همکارانش، علت عملکرد بهتر مدل ترکیبی این است که این مدل مزیت ثبات^۲ شبکه بدون ناظر کوهون را با توانایی شبکه با ناظر پرسپترون چندلایه در تشخیص تعداد نامحدود الگوها ترکیب کرده است.

افولابی و الوده (۲۰۰۷) نیز با استفاده از مدل‌های ترکیبی شبکه‌های خودسازمانده کوهون و پرسپترون چندلایه اقدام به پیش‌بینی قیمت سهام شرکت لیوسنت^۳ نمودند. نتایج تحقیق مزبور نشان می‌دهد که عملکرد شبکه عصبی ترکیبی در پیش

1- fine grain data series

2- stability

3- Lucent

بینی قیمت سهام شرکت لیوسنت در مقایسه با دو شبکه دیگر یعنی پرسپترون چندلایه و کوهونن بهتر بوده است.

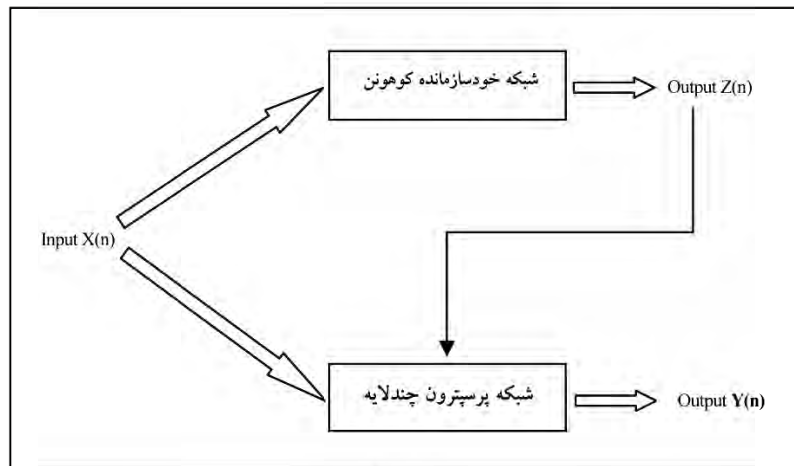
روش تحقیق و ریخت‌شناسی شبکه عصبی مصنوعی

جامعه آماری تحقیق، کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است که از این میان شرکت ایران خودرو بر اساس نمونه‌گیری قضاوتی به عنوان نمونه آماری انتخاب شده است. بدین ترتیب که در طی محدوده زمانی تحقیق (۱۳۸۵-۱۳۸۱) رتبه نقدشوندگی سهام کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار محاسبه و نقدشونده‌ترین سهم (ایران خودرو) انتخاب شده است. علت استفاده از معیار نقدشوندگی نیز این بوده است که اساساً هر چه تعداد داده‌ها در مدل شبکه عصبی بیشتر باشد، به عبارتی، تعداد داده‌های مفقود کمتر باشد، عملکرد شبکه بهتر خواهد بود.

متغیرهای مستقل تحقیق شامل دو بخش متغیرهای بیرونی (متغیرهای کلان اقتصادی) و متغیرهای درونی سهام مورد نظر می‌باشند. از میان متغیرهای کلان اقتصادی، قیمت طلا، نرخ ارز (یورو و دلار) و شاخص قیمت و بازده نقدی (شاخص بورس) به عنوان متغیرهای مستقل تحقیق انتخاب شده‌اند. با توجه به شناخت اغلب خانوارها از سرمایه‌گذاری در زمینه طلا نسبت به سایر بازارها، سرمایه‌گذاری در طلا به عنوان رقیب جدی برای بازار سرمایه محسوب می‌شود. از اینرو، بر اساس تغییرات شاخص قیمت جهانی طلا، تغییرات شاخص قیمت سهام بورس اوراق بهادار تهران قابل پیش‌بینی است [۱۱]. از سوی دیگر قیمت جهانی طلا مهمترین عامل تعیین کننده قیمت داخلی طلاست [۱۰]. بنابراین قیمت طلا به عنوان یکی از متغیرهای مستقل تحقیق انتخاب شده است. تحقیقات متعددی نیز وجود رابطه معنی‌دار بین نرخ ارز و قیمت سهام را تأیید می‌کنند که از آن جمله می‌توان به تحقیقات تقوی و همکاران (۱۳۷۸)، حاتمی (۱۳۸۰)، و زارع (۱۳۸۴) اشاره کرد. همچنین بنای سهام ایران خودرو در طی محدوده زمانی تحقیق، بر اساس محاسبه نرم‌افزار ره‌آورد نوین برابر ۲/۰۶ بوده است که نشان‌دهنده همبستگی بالای این سهم با شاخص قیمت و

بازده نقدی (شاخص بورس) می‌باشد. بنابراین شاخص قیمت و بازده نقدی (شاخص بورس) نیز به عنوان یکی از متغیرهای مستقل تحقیق انتخاب شده است. در این تحقیق از دیگر متغیرهای کلان اقتصادی به دلیل در دسترس نبودن اطلاعات روزانه، استفاده نشده است. سایر متغیرهای مستقل تحقیق (متغیرهای درونی سهم) عبارت از حجم معامله روزانه سهام شرکت، نسبت حجم معامله روزانه به تعداد کل سهام شرکت و قیمت سهام شرکت می‌باشند. برای استخراج داده‌های مربوط به سهام ایران خودرو از نرم افزار تخصصی رهاورد نوین و برای گردآوری داده‌های طلا و ارز از سایت‌های اعلام نرخ ارز و قیمت طلا و کتابخانه بانک مرکزی استفاده شده است.

برای پیش‌بینی قیمت سهام بر اساس متغیرهای مزبور، از شبکه عصبی ترکیبی متشکل از شبکه‌های پیش‌خور (پرسپترون چندلایه) و خودسازمانده کوهونن استفاده شده است. اساس و شالوده شبکه ترکیبی مورد استفاده، شبکه عصبی پیش‌خور بوده است و از شبکه خودسازمانده کوهونن به عنوان یکی از ورودی‌های آن استفاده شده است. همان‌گونه که در ادبیات تحقیق بیان شد نقش شبکه خودسازمانده کوهونن در ساختار شبکه ترکیبی، تجزیه داده‌ها به تعدادی طبقه معین است که امر تشخیص، طبقه‌بندی و کشف روابط بین داده‌ها را بهبود می‌بخشد [۱۷]. همچنین شبکه ترکیبی را قادر می‌سازد تا رفتار سری‌های داده‌های ریزبافت را در شبکه پیشرو تبیین کند. شکل ۱، ساختار کلی شبکه ترکیبی طراحی شده را نشان می‌دهد.



شکل ۱. ساختار کلی شبکه عصبی ترکیبی

در این شبکه ترکیبی، $X(n)$ بردار داده‌های ورودی یا همان متغیرهای مستقل مورد نظر است. همان‌گونه که در نمودار مشخص است، ورودی شبکه خودسازمانده کوهونن بردار $X(n)$ و خروجی آن، بردار $Z(n)$ ، داده‌های طبقه‌بندی شده یا گروه‌های مختلف داده‌ها است که شبکه کوهونن بر اساس داده‌های ورودی ایجاد کرده است. خروجی شبکه کوهونن به همراه متغیرهای مستقل اولیه به عنوان یکی از ورودی‌های شبکه پیش‌خور مورد استفاده قرار گرفته است تا دقت پیش‌بینی شبکه پیش‌خور افزایش یابد. در نهایت، خروجی شبکه پیش‌خور، $Y(n)$ ، بردار قیمت‌های پیش‌بینی شده شبکه ترکیبی محسوب می‌شود که خطای پیش‌بینی شبکه‌های ترکیبی بر اساس آن محاسبه و کمترین آنها با خطای شبکه پیش‌خور مورد مقایسه قرار گرفته است.

برای طراحی هر یک از شبکه‌های پیش‌خور و کوهونن از سه لایه و حداکثر ۷ نرون در هر لایه و ۷ وقفه^۱ استفاده شده است. بنابراین تعداد نرون‌های لایه میانی از ۱ تا ۷ (۷، حداکثر تعداد نرون‌های لایه ورودی است) تغییر می‌کند. معمولاً تعداد نرون‌های لایه میانی حداکثر دو برابر تعداد ورودی‌ها در نظر گرفته می‌شود [۱۳]. تعداد

لایه‌ها بر اساس نظریه وجود کولموگروف (مورد اشاره در ادبیات تحقیق) انتخاب شده است. معمولاً شبکه عصبی با یک لایه میانی و تعداد نرون‌های کافی برای اغلب کاربردهای اقتصادی مناسب است [۱۳]. در لایه میانی شبکه پیش‌خور از تابع فعالسازی تانژانت سیگموئید^۱ استفاده شده است که بر اساس تحقیقات مشابه، متداول‌ترین تابع فعالسازی برای استفاده در لایه میانی شبکه‌های عصبی می‌باشد [۳۶]. در لایه خروجی نیز از تابع پیورلاین^۲ استفاده شده است. مزیت استفاده از تابع پیورلاین در لایه خروجی نسبت به سایر توابع این است که خروجی مدل در دامنه محدود و مشخصی قرار نمی‌گیرد و می‌تواند هر عددی باشد. از میان الگوریتم‌های یادگیری مختلف، الگوریتم لونیبرگ مارکواریت^۳ انتخاب شده است. این الگوریتم علاوه بر این که کمینه خطای شبکه را به دست می‌دهد، نرخ همگرایی پایینی نیز دارد، که سبب می‌شود شبکه بسیار سریع‌تر از زمانی که الگوریتم‌های متعارف استفاده می‌شوند، همگرا شود [۵]. برای افزایش روایی شبکه و جلوگیری از عارضه بیش‌برازش^۴، از اعتبارسنجی مبنایی^۵ شبکه عصبی با استفاده از روش توقف زودهنگام^۶ استفاده شده است^۷. ضمن اینکه استفاده از اعتبارسنجی مبنایی باعث کاهش خطای تعمیم^۸ نیز می‌گردد [۵]. بنابراین مجموعه داده‌های مورد استفاده در این تحقیق به دو قسمت تقسیم شده است. بخش نخست برای آموزش و اعتبارسنجی شبکه‌ها و بخش دوم برای آزمایش و مقایسه دقت پیش‌بینی شبکه عصبی ترکیبی با شبکه پیش‌خور مورد استفاده قرار گرفته است. اکثر محققین در تقسیم داده‌ها، ۸۰ درصد مشاهدات را برای مجموعه آموزش و باقیمانده را برای مجموعه آزمایش پیشنهاد کرده‌اند [۱۳]. در این تحقیق به منظور افزایش دقت برازش مدل، ۸۵ درصد داده‌ها برای آموزش و باقیمانده برای آزمایش مدل در نظر گرفته شده است. برای مقایسه دقت پیش‌بینی شبکه‌ها از معیار میانگین مجذور خطا (MSE) و برای پیاده

1- tansig

2- pureline

3- Levenberg-Marquardt

4- overfitting

5- cross-validation

6- early stopping

۷- برای آشنایی بیشتر با این روش، به حنفی‌زاده و همکاران (۱۳۸۶) مراجعه نمایید.

8- generalization error

سازی شبکه‌های عصبی، از محیط برنامه‌نویسی MATLAB استفاده شده است.

نتایج

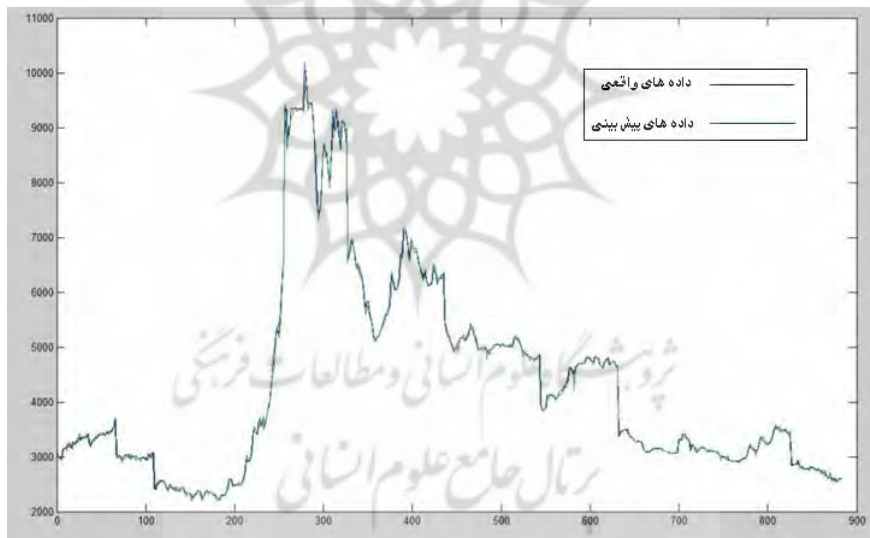
در مدل پیش‌خور، پس از آموزش شبکه‌ها با ۸۵ درصد داده‌ها، آزمایش شبکه‌ها بر روی ۱۵ درصد باقیمانده داده‌ها انجام گرفته است که بر اساس معیار MSE از میان $(7^2 + 7^3 + 7^4)$ شبکه ساخته شده، شبکه‌ای که دارای کمترین MSE بوده است، به‌عنوان بهینه‌ترین شبکه انتخاب شده است. این شبکه دارای ۳ لایه با چیدمان ۶ نرون در لایه اول، ۷ نرون در لایه دوم، ۴ نرون در لایه سوم و ۱ وقفه بوده است. سپس شبکه بهینه مجدداً بر روی داده‌های آزمایش اجرا شده است که MSE آن $7/9724e-005$ به دست آمده است. شکل ۲، تفاوت میان قیمت‌های پیش‌بینی شده توسط شبکه عصبی پیش‌خور و قیمت‌های واقعی را نشان می‌دهد.



شکل ۲. مقایسه پیش‌بینی شبکه عصبی پیش‌خور و داده‌های واقعی

برای طراحی شبکه عصبی ترکیبی متشکل از شبکه عصبی پیش‌خور و شبکه خودسازمانده کوهونن، یک بخش شبکه ترکیبی که شبکه عصبی پیش‌خور است، ثابت در نظر گرفته می‌شود. بدین ترتیب که از بهینه‌ترین شبکه پیش‌خور طراحی

شده از میان ۲۷۹۳ شبکه عصبی به عنوان شبکه پیش خور در ساختار شبکه عصبی ترکیبی استفاده شده است. سپس بخش دیگر شبکه ترکیبی که شبکه خودسازمانده کوهونن است، بر اساس تعداد لایه‌ها، تعداد نرون‌های موجود در هر لایه و حداکثر وقفه مورد استفاده، مورد تغییر قرار گرفته و عملکرد هر شبکه بر اساس معیار MSE اندازه‌گیری شده است. سرانجام از میان ۳۹۹ شبکه عصبی، شبکه عصبی متشکل از سه لایه با چیدمان ۶ نرون در لایه اول، ۵ نرون در لایه دوم، ۶ نرون در لایه سوم و ۷ وقفه، با کمترین MSE به عنوان شبکه عصبی بهینه انتخاب شده است. سپس شبکه بهینه که شبکه ترکیبی بهینه محسوب می‌شود بر روی داده‌های آزمایش اجرا شده است که $MSE = 1/5032e-006$ به عنوان خطای پیش‌بینی شبکه عصبی ترکیبی به دست آمده است. شکل ۳، تفاوت میان قیمت‌های پیش‌بینی شده توسط شبکه عصبی ترکیبی و قیمت‌های واقعی را نشان می‌دهد.



شکل ۳. مقایسه پیش‌بینی شبکه عصبی ترکیبی و داده‌های واقعی

مقایسه نتایج به دست آمده از شبکه عصبی ترکیبی و شبکه پیش‌خور به شرح جدول ۲ است:

جدول ۲. مقایسه خطای پیش‌بینی شبکه عصبی ترکیبی و شبکه پیش‌خور

مدل	خطای پیش‌بینی (بر اساس MSE)
شبکه عصبی ترکیبی	$1/5032e - 006$
شبکه عصبی پیش‌خور	$7/9724e - 006$

جمع‌بندی

امروزه شبکه‌های عصبی مصنوعی جایگاه مهمی در ادبیات پیش‌بینی متغیرهای اقتصادی به خود اختصاص داده‌اند. انعطاف در تخمین دامنه وسیعی از روابط و توابع بین مقادیر داده‌ها و ستاده‌ها، عدم نیاز به اعمال فرض‌های آماری خاص در مورد رفتار متغیرها و ارائه عملکرد بهتر نسبت به روش‌های سنتی در کشف روابط پیچیده و غیرخطی از جمله مزایای آنها به شمار می‌رود. ضمن اینکه شبکه‌های عصبی در مواجهه با میزان زیاد داده‌های مفقود و اغتشاش داده‌های مالی، نسبت به روش‌های سنتی عملکرد بهتری ارائه می‌کنند. از سوی دیگر، تحقیقات اخیر به سمت ترکیب مدل‌های مختلف شبکه‌های عصبی حرکت کرده است. در این تحقیق نیز با استفاده از شبکه‌های عصبی ترکیبی متشکل از شبکه‌های پیش‌خور و خودسازمانده کوهونن، نسبت به پیش‌بینی قیمت سهام اقدام و نتیجه آن با عملکرد شبکه‌های پیش‌خور مورد مقایسه قرار گرفته است. نتایج تحقیق برای سهام شرکت ایران خودرو نشان می‌دهد که ترکیب شبکه خودسازمانده کوهونن با شبکه پیش‌خور، موجب بهبود عملکرد و افزایش دقت شبکه پیش‌خور به میزان ۸۱٪ در پیش‌بینی قیمت سهام می‌شود. به عبارت دیگر خطای پیش‌بینی قیمت سهام که بر اساس معیار MSE اندازه‌گیری شده است، در صورت استفاده از مدل ترکیبی شبکه‌های عصبی پیش‌خور و خودسازمانده کوهونن نسبت به حالتی که از مدل منفرد پیش‌خور بدین منظور استفاده می‌شود، به میزان ۸۱٪ کاهش می‌یابد. علت عملکرد بهتر مدل ترکیبی یا کاهش خطای پیش‌بینی آن نسبت به مدل منفرد پیش‌خور همان گونه که در ادبیات تحقیق اشاره شد این است که مدل ترکیبی مزیت ثبات شبکه

بدون ناظر کوهونن را با توانایی شبکه با ناظر پرسپترون چندلایه در تشخیص تعداد نامحدود الگوها ترکیب کرده است.

باید توجه داشت که نتیجه گزارش شده در این تحقیق تنها روی یکی از نقدشونده ترین سهام های فهرست شده در بورس اوراق بهادار تهران صورت گرفته است و تعمیم نتایج این تحقیق به بورس اوراق بهادار تهران باید با احتیاط صورت پذیرد و نیاز به آزمایشات محاسباتی بیشتری دارد.

پیشنهاد برای تحقیقات آتی

در این تحقیق، عملکرد شبکه عصبی ترکیبی متشکل از شبکه های عصبی پیش خور و خودسازمانده کوهونن با عملکرد شبکه عصبی پیش خور در پیش بینی قیمت سهام مورد مقایسه قرار گرفت. برای انجام تحقیقات بیشتر و تکمیلی در این زمینه پیشنهادات ذیل ارائه می گردد:

- پیشنهاد می گردد در تحقیقات آتی، عملکرد شبکه های عصبی ترکیبی و پیش خور در پیش بینی شاخص کل یا شاخص یک صنعت خاص در بورس اوراق بهادار تهران مورد بررسی قرار گیرد.
- در تحقیقات آتی که از شبکه های عصبی مصنوعی برای پیش بینی قیمت سهام استفاده می شود از ضریب P/E نیز به عنوان یکی از متغیرهای درونزای تحقیق استفاده گردد و نیز در متغیرهای برونزا به جای شاخص قیمت و بازده نقدی (شاخص بورس) از شاخص قیمت استفاده شود.
- به نظر می رسد مدل های ترکیبی شبکه های عصبی مصنوعی برای پیش بینی در سایر زمینه های مالی نیز ابزار کارآمدی باشند. از اینرو پیشنهاد می شود از مدل های مزبور برای پیش بینی متغیرهایی مانند نرخ ارز و قیمت طلا نیز استفاده گردد.
- در اکثر تحقیقات پیشین (و نیز تحقیق حاضر) از شبکه های عصبی پیش خور (به صورت ترکیبی یا منفرد) برای پیش بینی قیمت سهام استفاده شده است. پیشنهاد می شود در تحقیقات آتی از شبکه های TDNN که از قابلیت های خوبی

برخوردارند به صورت ترکیبی یا منفرد برای پیش‌بینی قیمت سهام استفاده شود.

- برای افزایش دقت پیش‌بینی می‌توان از ترکیب شبکه‌های عصبی ترکیبی (مانند شبکه ترکیبی مورد استفاده در تحقیق حاضر) با سایر روش‌های هوش مصنوعی مانند الگوریتم ژنتیک و منطق فازی استفاده کرد.



منابع و مأخذ

۱. بت شکن، محمود (۱۳۷۹)؛ «پیش‌بینی قیمت سهام با استفاده از شبکه‌های عصبی - فازی و مقایسه آن با الگوهای خطی پیش‌بینی»، پایان‌نامه کارشناسی ارشد، دانشگاه تهران.
۲. تقوی، مهدی و همکاران (۱۳۷۸)؛ «بررسی متغیرهای اقتصادی اثرگذار بر شاخص قیمت سهام بورس اوراق بهادار تهران»، مجله برنامه و بودجه، شماره ۴۰ و ۴۱، صفحات ۶۰-۳۱.
۳. حاتمی، احمد (۱۳۸۰)؛ «شناسایی عوامل مؤثر بر قیمت سهام در بورس اوراق بهادار تهران و ارائه مدلی ریاضی برای پیش‌بینی تغییرات آن»، پایان‌نامه کارشناسی ارشد، دانشگاه علم و صنعت ایران.
۴. حسینیان، نرگس (۱۳۸۶)؛ «بررسی روند قیمت سهام با استفاده از شبکه‌های عصبی و مقایسه آن با الگوهای خطی»، پایان‌نامه کارشناسی ارشد، دانشگاه آزاد اسلامی، واحد تهران مرکز.
۵. حنفی‌زاده، پیام و همکاران (۱۳۸۶)؛ «بررسی مقایسه‌ای توان پیش‌بینی شبکه‌های عصبی با روش توقف زود هنگام و فرایند سری‌های زمانی خودبازگشت در برآورد نرخ تورم»، تحقیقات اقتصادی، شماره ۸۱، صفحات ۳۵-۲۵.
۶. خالوزاده، حمید (۱۳۷۵)؛ «مدلسازی غیرخطی و پیش‌بینی رفتار قیمت سهام در بازار بورس تهران»، رساله دکتری، دانشکده تربیت مدرس.
۷. راعی، رضا (۱۳۷۷)؛ «طراحی مدل سرمایه‌گذاری مناسب در سبد سهام با استفاده از شبکه‌های عصبی»، رساله دکتری، دانشگاه تهران.
۸. رجب‌زاده قطرمی، علی (۱۳۷۷)؛ «ارزیابی ترکیبی روش‌های پیش‌بینی و ارائه مدل بهینه برای پیش‌بینی قیمت سهام در بورس اوراق بهادار تهران»، پایان‌نامه کارشناسی ارشد، دانشگاه تربیت مدرس.
۹. زارع، هاشم (۱۳۸۴)؛ «بررسی رفتار شاخص قیمت سهام در ایران: رهیافتی هم‌تجمعی»، پایان‌نامه کارشناسی ارشد، دانشگاه شیراز، دانشکده اقتصاد.
۱۰. سرافراز، لیلا و امیر افسر (۱۳۸۴)؛ «بررسی عوامل مؤثر بر قیمت طلا و ارائه مدل پیش‌بینی بر مبنای شبکه‌های عصبی فازی»، فصلنامه پژوهش‌های اقتصادی، شماره ۱۶.

۱۱. صمدی، سعید و همکاران (۱۳۸۶)؛ «بررسی میزان اثرپذیری شاخص قیمت سهام بورس اوراق بهادار تهران از قیمت جهانی نفت و طلا (مدل‌سازی و پیش‌بینی)»، تحقیقات اقتصادی ایران (فصلنامه بررسیهای اقتصادی)، صفحات ۵۱-۲۵.
۱۲. فدایی نژاد، محمد (۱۳۷۳)؛ «آزمون ضعیف نظریه بازار کارای سرمایه در بورس اوراق بهادار»، تحقیقات مالی، شماره ۵ و ۶.
۱۳. مرادی، سردار و همکاران (۱۳۸۷)؛ «پیش‌بینی شاخص قیمت مصرف‌کننده در ایران با استفاده از روشهای ARIMA و شبکه عصبی مصنوعی»، فصلنامه مدرس علوم انسانی.
۱۴. مشیری، سعید و حبیب مروت (۱۳۸۵)؛ «پیش‌بینی شاخص کل بازدهی سهام تهران با استفاده از مدل‌های خطی و غیرخطی»، پژوهشنامه بازرگانی، شماره ۴۱، صفحات ۲۷۵-۲۴۵.
۱۵. نمازی، محمد و همکاران (۱۳۷۴)؛ «بررسی کارایی بازار بورس تهران»، تحقیقات مالی، شماره ۷ و ۸.
۱۶. هادی‌پور، حسین (۱۳۸۲)؛ «تعیین بهترین مدل جهت پیش‌بینی قیمت سهام در گروه صنایع غذایی و آشامیدنی بورس اوراق بهادار تهران»، پایان‌نامه کارشناسی ارشد، مؤسسه عالی آموزش و پژوهش مدیریت و برنامه‌ریزی.
17. Afolabi, M. O. and Olude, O. (2007); "Predicting Stock Prices Using a Hybrid Kohonen Self Organizing Map (SOM)", *40th Hawaii International Conference on System Sciences*.
18. Barkoulas, J. T., Baum, C. F. and Travlos, N. (1997); "Long Memory in the Greek Stock Market", *Working Paper*, Boston Collage, Chestnut Hill.
19. Bodis, L. (2004); "Financial Time Series Forecasting Using Artificial Neural Networks", Master's thesis, The Pretsch Group, Babes-Bolyai University.
20. Castiglione, F. (2000); "Forecasting Price Increments Using an Artificial Neural Network", *Adv. Complex Systems*, 1, 1-12.
21. Connor, J., Martin, R. and Atlas, L. (1994); "Recurrent Neural Networks and Robust Time Series Prediction", *IEEE Transactions on Neural Networks*, vol. 3, No. 2, pp. 240-254.
22. Fausett, L. (1994); "Fundamentals of Neural Networks: Architecture, Algorithms and Applications", Prentice Hall, MA.
23. Hamid, Sh. A. (2004); "Primer on Using Neural Networks for Forecasting Market Variables", *Working Paper*, No. 2004-03, Southern New Hampshire University.

24. Hanafizadeh, P., Salahi Parvin, E., Asadolahi, P. and Gholami, N. (2008); "Ensemble Strategies to Build Neural Network to Facilitate Decision Making", *Journal of Industrial Engineering International*, Vol. 4, No. 6.
25. Hsu, S.-H., Hsieh, J. P. -A., Chih, T. -C., Hsu, K. and Tsai, M. -H. (2008); "A Two-Stage Architecture for Stock Price Forecasting by Integrating Self-Organizing Map and Support Vector Regression", *Expert Systems With Applications*, doi: 10.1016/j.eswa.2008.10.065
26. Hui, S. C., Yap, M. T. and Prakash P. (2000); "A Hybrid Time Lagged Network For Predicting Stock Prices", *International Journal of the Computer, the Internet and Management*, Volume 8 (Number 3).
27. Kolarik, T. and Rudorfer G. (1994); "Time Series Forecasting Using Neural Networks", *APL94, 1994 ACM*, 0-89791-675-1/94/0009.
28. Lakonishok, J., Shleifer, A. and Vishny, R. (1994); "Contrarian Investment, Extrapolation, and Risk", *Journal of Finance*, Volume 49 (Number 5):1541–1578.
29. Oomen, R. C. A. (2001); "Using High Frequency Stock Market Index Data to Calculate, Model and Forecast Realized Volatility", Working Paper, European University Institute, Department of Economics, Viadei Roccetinni, Italy.
30. Panda, Ch. and Narasimhan, V. (2006); "Predicting Stock Returns: An Experiment of the Artificial Neural Network in Indian Stock Market", *South Asia Economic Journal* Vol. 7, No.2.
31. Refenes, A. N., Azema-Barac, M. and Zapranis, A. D. (1993); "Stock Ranking: Neural Networks Vs Multiple Linear Regression", *IEEE International Conference on Neural Networks*, pp. 1419-1426.
32. Rudorfer, G. (1995); "Early Bankruptcy Detection Using Neural Networks", In *International Conference on APL*, pages 171–178, Proceedings of the international conference on Applied programming languages.
33. Rurkhamet, B., Chuitma, P. and Reodecha, M. (1998); "Comparative Study of Artificial Neural Network and Regression Analysis for Forecasting New Issued Banknotes", *Journal of Science Technology*, Vol. 3, No. 2.
34. Shachmurove, Y. (2002); "Applying Artificial Neural Networks to Business, Economics and Finance", *Penn CARESS Working Papers*, UCLA Department of Economics.
35. Shachmurove, Y. and Witkowska, D. (2000); "Utilizing Artificial Neural Network Model to Predict Stock Markets", *CARESS Working Paper*.

36. Smith, K. A. and Gupta, J. N. D. (2002); "Neural Networks in Business: Techniques and Applications", Idea Group Publishing.
37. Tang Z., de Almeida, Ch., Fishwick, P. A. (1991); "Time Series Forecasting Using Neural Networks Vs. Box- Jenkins Methodology", SIMULATION, Vol. 57, No. 5, 303-310.
38. Trippi, R. and DeSieno, D. (1992); "Trading Equity Index Futures with a Neural Network", Journal of Portfolio Management, pp. 27-33.
39. Vanstone, B., Finnie, G. and Tan, C. (2004); "Applying Fundamental Analysis and Neural Networks in the Australian Stock Market", Bond University School of IT.
40. Warner, B. and Misra, M. (1996); "Understanding Neural Networks as Statistical Tools", the American Statistician, Vol. 50, No. 4.
41. Zhang, D., Jiang, Q. and Li, X. (2004); "Application of Neural Networks in Financial Data Mining", Transaction on Engineering, Computing and Technology, Vol. 1.

