

## استفاده از شبکه های عصبی ترکیبی آموزش پذیر اصلاح شده برای پیش بینی روند قیمت سهام (مطالعه موردی : شرکت پتروشیمی خارگ)

دکتر ابوالفضل شهرآبادی\*

دکتر رضا ابراهیم پور\*\*

حسین نیکو\*\*\*

### چکیده

این مقاله مطالعه ای برای مقایسه توان پیش بینی روند قیمت سهام با استفاده از شبکه های عصبی ترکیبی آموزش پذیر اصلاح شده در مقابل سایر شبکه های آموزش پذیر و غیر آموزش پذیر ترکیبی است. داده های تاریخی به کار رفته در این تحقیق از شرکت پتروشیمی خارگ، پذیرفته شده در بورس اوراق بهادار ایران بدست آمده اند. شرکت پتروشیمی خارگ از بزرگترین تولید کنندگان ایرانی محصولات پتروشیمی از جمله متانول است و به دلیل صادرات محصولات، قیمت سهام آن در بورس اوراق بهادار ایران بسیار متأثر از قیمت جهانی محصولات پتروشیمی، به ویژه متانول، می باشد. بنابراین قیمت سهام آن، نسبت به شرکت هایی که فاقد صادرات محصولات به بازار های جهانی هستند، به گونه ای شفاف تغییر می نماید. از آنجا که در بورس اوراق بهادار ایران نمونه مشابه دیگری که دارای سابقه قیمتی کافی و تعداد سهام شناور بالا باشد<sup>۱</sup> وجود ندارد، لذا سهام پتروشیمی خارگ مناسبترین گزینه برای انجام فرآیند تحقیق تشخیص داده شد. نتایج این تحقیق نشان می دهد که چگونه شبکه های عصبی ترکیبی آموزش پذیر اصلاح شده می تواند گوی سبقت را در قابلیت پیش بینی روند قیمت سهام از سایر شبکه های ترکیبی آموزش پذیر و غیر آموزش پذیر برآید. این تحقیق همچنان نشان می دهد که چگونه با استفاده از روش پیشنهادی این مقاله می توان بدون نیاز به اطلاعات تفصیلی و جامع به قابلیت پیش بینی نسبتاً دقیقی دست یافت.

### واژگان کلیدی :

پرسپترون های چند لایه، شبکه های عصبی ترکیبی آموزش پذیر<sup>۲</sup>، طرح و جانمایی<sup>۳</sup>، الگوریتم پس انتشار<sup>۴</sup>، پیش بینی سریهای زمانی<sup>۵</sup>.

\* استادیار، عضو هیات علمی تمام وقت دانشگاه زنجان (Shahrabadi@tse.ir)

زنجان - اعتمادیه - خیابان معلم - دانشکده علوم انسانی دانشگاه آزاد اسلامی واحد زنجان

\*\* استادیار، عضو هیات علمی دانشگاه شهید رجایی (ebrahimpour@ipm.ir)

تهران - لویزان - دانشگاه تربیت دبیر شهید رجایی - دانشکده برق - گروه الکترونیک

\*\*\* دانش آموخته کارشناسی ارشد مدیریت بازرگانی (گرایش مالی)، دانشگاه آزاد اسلامی، واحد قزوین (Hossein.nikoo@gmail.com)

قزوین - بالاتر از پونک - دانشکده مدیریت و حسابداری دانشگاه آزاد اسلامی، واحد قزوین

نویسنده مسئول یا طرف مکاتبه : حسین نیکو

۱. به اندازه ای که دستکاری قیمتی آن آسان نباشد

2. Trainable Neural Network Ensembles

3. Topology

4. Back Propagation algorithm

5. Time Series Prediction

## مقدمه

## مقدمه ای بر شبکه‌های عصبی

یکی از روش‌های محاسباتی مورد توجه در علوم مختلف، به ویژه در علوم مالی، الگوریتم‌های موجود در حوزه تحقیق در عملیات<sup>۱</sup> می‌باشد که مسائل را بطور سیستماتیک (نورویگ، ۱۳۸۳، ۷-۱۱) مورد بررسی قرار می‌دهند. این الگوریتم‌ها برای بهینه‌سازی مداوم تا رسیدن به بهترین جواب، برای مسأله در دست بررسی، مورد استفاده قرار می‌گیرند. الگوریتم‌های هوش مصنوعی بخشی از الگوریتم‌های حوزه تحقیق در عملیات را تشکیل می‌دهند. این الگوریتم‌ها توان این را دارند که در شرایط عدم اطمینان بهترین نتیجه را ارائه دهند، داده‌ها را استنتاج نمایند و ویژگی‌های آنها را کشف کنند (Haykin, 1999, 173). تفاوت عمده آنها با روش‌های آماری این است که اساساً مثل روش‌های آماری مبتنی بر الگو<sup>۲</sup> نیستند؛ بلکه مبتنی بر داده‌های ورودی خود هستند<sup>۳</sup> و نیازی به تفسیر جزئیات برای مدل مورد استفاده ندارند (Enke&Thawornwong, 2004, 207). در این میان شبکه‌های عصبی پرکاربردترین الگوریتم‌های هوش مصنوعی هستند. این الگوریتم‌ها، الگوریتم بهینه‌سازی مانند سایر الگوریتم‌ها نیستند بلکه الگوریتم‌های مشتق‌گیری پیاپی هستند که با کاهش شیب منحنی خطا چه در سطح و چه در فضا و با قدرت همگرایی قابل تنظیم و کشف نقطه بهینه در تمام سطوح و احجام، یافتن بهترین جواب ممکن را عملی می‌سازند؛ بنابراین توانایی منحصر به فردی در حل ارتباطات غیر خطی دارند (Haykin, 1999, 1-45).

استفاده از شبکه‌های عصبی در علوم بازرگانی و مالی عمری بیش‌تر از دو دهه ندارد و بسیار جوان است. موارد کلی که در آن از شبکه‌های عصبی استفاده شده است عبارتند از:

- پیش‌بینی روند‌های آتی با استفاده از داده‌های تاریخی که به عنوان ورودی به مدل داده می‌شود.<sup>۴</sup>
- طبقه‌بندی داده‌هایی که تفکیک آنها با شیوه‌های موجود بسیار مشکل و یا غیر ممکن است، به گروه‌های تعریف شده، با تکیه بر ویژگی‌های مستتر در داده‌های ورودی<sup>۵</sup>
- خوشه‌بندی داده‌های ورودی، بر اساس شباهت موجود، به گروه‌های واقعی و قابل استناد<sup>۶</sup>
- اولین بار استفاده از شبکه‌های عصبی در پیش‌بینی قیمت سهام در سال ۱۹۸۸ توسط وایت<sup>۷</sup> و بر روی سهام شرکت آی بی ام<sup>۸</sup> صورت گرفت. پس از آن مهمترین تحقیقات توسط شونبرگ در سال ۱۹۹۰<sup>۹</sup>، رِفِنس و همکاران در سال ۱۹۹۳<sup>۱۰</sup>، گیلز و همکاران در سال ۱۹۹۷<sup>۱۱</sup> و ساگار و لی در سال ۱۹۹۹<sup>۱۲</sup> صورت گرفته است. روش‌های استفاده شده در تحقیقات قبلی طیف وسیعی از الگوها از جمله شبکه‌های ساده (مثل پرسپترون‌های چند لایه) تا شبکه‌های پیچیده‌تر (مثل<sup>۱۳</sup>،<sup>۱۴</sup> و<sup>۱۵</sup>) را شامل می‌شود. با توجه به تحقیقات انجام شده هدف این تحقیق ارائه مدلی مناسب و سازگار با بورس اوراق بهادار ایران می‌باشد. میزان سازگاری روش مورد استفاده در این تحقیق از طریق بررسی الگوهای مختلف شبکه‌های عصبی ترکیبی سنجیده می‌شود. الگوی پیشنهادی در این مقاله (شبکه‌های عصبی ترکیبی آموزش پذیر اصلاح شده) تاکنون در بورس اوراق بهادار ایران مورد استفاده قرار نگرفته است. لازم به ذکر است در این مقاله به دلیل ارائه نتایج پیش‌بینی انجام شده بر روی

4. Time series prediction;(Smith & Gupta, 2001, 188-244), (Abdullah & Ganapathy, 2000 157-161), (Atya, & et al 1997, 2112-2115), (Baba, 1992, 371-377)

5. (Smith & Gupta, 2002, 10-140)

6. (Ibid, 3)

7. White

8. IBM

9. Shoneburg, 1990

10. Refenes & et al., 1993

11. Giles & et al., 1997

12. Sagar & Lee, 1999

13. Radial Base functions

14. Dual Network Modules

15. Ensembles

1. Operations Research

2. Model driven

3. Data driven

سیناپسی آزاد شوند این حالت باعث می شود دروازه های بیشتری روی دندریت مقابل باز شود. به این ترتیب سلول قادر خواهد بود با تحریک کمتری فعال شود.

توانایی تغییر میزان اتصال بین سلول ها از مهم ترین مشخصه های الگو های شبکه عصبی می باشد. این تقویت اتصالات نوعی از یادگیری است که اصطلاحاً به آن یادگیری تشویقی گفته می شود. در این روش یادگیری، از سعی و خطا برای تعیین میزان اتصال نورون ها استفاده می شود، یعنی یادگیری به صورتی رخ می دهد که برای انجام هر کاری از پی بردن به ارتباط علت و معلولی دو اتفاق گرفته تا پردازش تصاویر دریافتی از چشم و ... یک ساختار نورونی یکتا وجود دارد و این ساختار نورونی یکتا بهترین جواب را خواهد داد ، به عبارت دیگر داده های مربوط به هر کاری باید از مسیر نورون های خاصی عبور کند. لذا با ورود هر دسته از داده ها، نورون هایی که برای پردازش آن داده ها اتصالاتشان تقویت شده احتمال فعال شدنشان بیشتر است. بنابراین فعال شدن اولین نورون، داده ها را در مسیری که از قبل تقویت شده (اتصالات آن تقویت شده) پیش خواهد برد. در شکل (۱) ساختار یک نورون طبیعی نشان داده شده است.


سریه های زمانی به صورت دو طبقه صعودی و نزولی، الگوهای ارائه شده با عنوان طبقه بند ذکر گردیده اند<sup>۱</sup>.

استفاده از شبکه های عصبی مصنوعی کارایی خود را در یافتن روابط غیر خطی موجود در دنیای واقعی به اثبات رسانیده و توان کشف رابطه میان داده ها بدون وجود اطلاعات مبسوط از امتیازات این الگوریتم هوش مصنوعی می باشد. فرار از نقاط بهینه محلی و رسیدن به نقطه بهینه سراسری (Hatami & Ebrahimpour, 2007, 127-131). قدرت این روش را حتی در قیاس با سایر الگوریتم های هوش مصنوعی به رخ می کشد.

(Smith & Gupta, 2002, 1-26, Trippi & Turban, 1993, 42-46, Fernandez & Gomez, 2005, 1177-1191)

### نحوه عملکرد شبکه های عصبی مصنوعی

نورون ها عناصر اصلی تشکیل دهنده مغز هستند و به تنهایی مانند یک واحد پردازش منطقی عمل می کنند. مغز انسان متشکل از هزاران میلیارد نورون است و هر نورون هم بطور تقریبی به هزار نورون دیگر مرتبط است. دانشمندان بر این باورند که یادگیری در مغز هنگامی صورت می گیرد که شدت اتصال یک سلول به سلول دیگر در محل سیناپس ها اصلاح می شود . به این معنی که ناقل های عصبی با سهولت بیشتری می توانند در شکاف

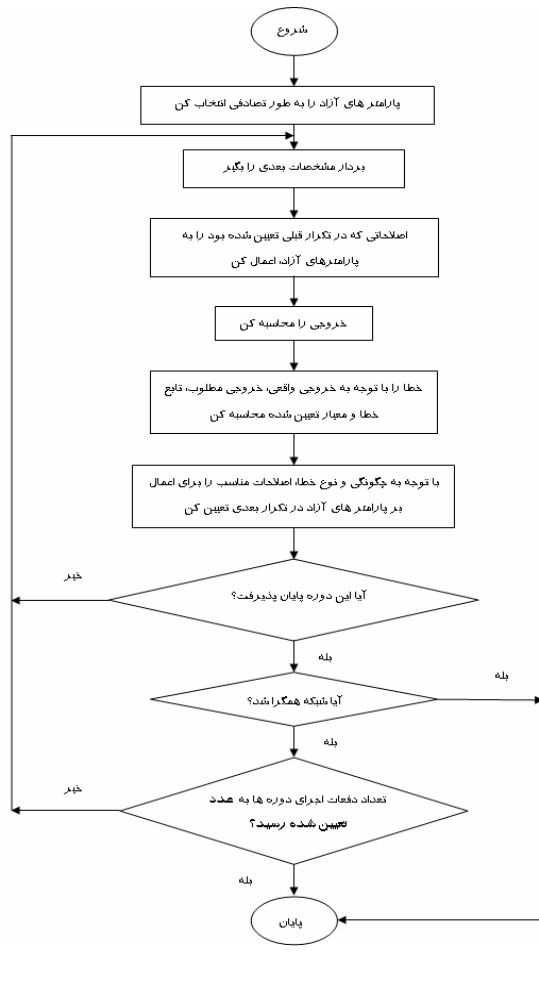


شکل (۱). نمای کلی یک نورون: بدنه اصلی نورون (Soma) ، رشته های ورودی (Dendrit) ، رشته خروجی (Axon) ، نقاط اتصال آکسون یک نورون به دندریت نورون دیگر (Synapse)

۱. الگو های ارائه شده در این تحقیق بطور کلی عبارتند از: طبقه بند های پایه و ترکیب طبقه بندها

تکرارها منجر به مقدار صفر برای خطای منتظره شود (شبکه به همگرایی برسد). پس از رسیدن به این مرحله پارامترهای آزاد دوباره دستکاری نخواهند شد. البته اگر تکرارها را عدد مشخصی قرار دهیم ممکن است شبکه پیش از رسیدن به همگرایی کار را متوقف کند یا با رسیدن به خطای صفر برای تمام تکرارها باز هم به آموزش ادامه داده و منجر به بیش آموختگی<sup>۲</sup> - یعنی ناتوانی در پیش بینی و بسط الگوی رفتاری داده های تاریخی به داده های آتی - شود. بنابراین انتخاب تعداد مناسب برای دوره ها حائز اهمیت است. لازم به ذکر است صفر بودن مقدار خطا به معیار اندازه گیری ما بستگی دارد. معیار مناسب خطا با توجه به نتایج به دست آمده در دوره های مختلف انتخاب می شود<sup>۳</sup>.

شکل ۳. الگوریتم کلی یادگیری با ناظر شبکه های عصبی




## 2. Over Training

۳. در این تحقیق معیار خطای مورد استفاده حداقل مجذور خطاها و محدوده آن تا  $10^{-5}$  است.

## الگوی شبکه عصبی

شکل (۲) یک نورون مصنوعی (پرسپترون) را نشان می دهد. در این شکل،  $X_i$  ها ورودی های دندریت ها هستند و  $Y$  خروجی یا آکسون است. شدت اتصال نورون ها در سیناپس (محل اتصال دو نورون به یکدیگر) توسط ضریب  $W_i$  که قبل از رسیدن ورودی به نورون در آن ضرب می شود در الگوی زیر نشان داده شده است.  $W_i$  را وزن ورودی  $X_i$  می نامند.



شکل ۲. ساختار اساسی یک نورون مصنوعی (پرسپترون)

الگوریتم ساده شده شبکه های عصبی در شکل (۳) به نمایش در آمده است. در این الگوریتم ابتدا پارامترهای آزاد اولیه (وزن های ورودی یعنی  $W_i$  ها) بصورت تصادفی به شبکه داده می شود. به ازای هر ورودی متغیر، خروجی مشخصی هم به شبکه داده می شود. در این حالت اگر اختلاف خروجی حاصل از شبکه با خروجی مورد نظر صفر باشد، شبکه درست عمل کرده است و اگر مخالف با صفر باشد، شبکه به تغییر پارامتر اولیه برای کاهش میزان خطا نیاز دارد. این مرحله را یک تکرار می نامیم. تکرارها را تا دستیابی به مقدار صفر برای خطای منتظره ادامه می دهیم. در این مرحله یک دوره<sup>۱</sup> کامل شده است، بنابراین به دوره دوم می رویم. دوره های بعدی تا زمانی ادامه می یابند که یک دوره کامل متشکل از

## مقدمه ای بر بورس اوراق بهادار

بورس اوراق بهادار برآیندی است از عرضه و تقاضا، احتمال ها، ترجیح ها و جنبه های روانشناختی، سیاسی، جامعه شناختی، زیست شناختی و فیزیولوژیک طبیعت انسان. همانطور که فاما اذعان داشت قیمت ها بطور کامل مبین اطلاعات موجود در بازار هستند. در واقع اطلاعات موجود بر روی قیمت سهام یا هر دارایی مالی مورد بحث اثر خود را می گذارند. بنابراین با توجه به اهمیت عنصر قیمت در دارایی مالی الگوی پیشنهادی ما توسط شبکه های عصبی به عنوان ورودی از قیمت های روزانه استفاده می کند تا بتواند روند قیمتی را جستجو نماید. با توجه به ادبیات نظری سه دهه گذشته در حوزه فرضیه بازار کارا، می توان دریافت که روشهای خطی و غیر خطی آماری نمی توانند ما را در رسیدن به نتایج قدرتمند در پیش بینی های مالی کمک کنند (به دلیل ناتوانی آنها در فرموله کردن روابط فیما بین قیمت ها و اطلاعات تاثیر گذار بر قیمت ها). بنابراین ما مبنای فعالیت خود را بر شبکه های عصبی قرار می دهیم که توانایی ویژه ای در حل مسائل قدیمی با استفاده از یافته های جدید دارند. تعریف جنسن از کارایی بازار به صورت زیر است: یک بازار زمانی کارا است که مجموعه اطلاعاتی مانند  $\theta_t$  نتواند در کسب بازده اقتصادی توسط معاملات مبتنی بر این مجموعه اطلاعاتی نقش داشته باشد. اگر  $\theta_t$  مجموعه ای از اطلاعات تاریخی باشد سطح کارایی مورد بررسی سطح ضعیف، اگر  $\theta_t$  نه تنها مجموعه ای از اطلاعات تاریخی بلکه شامل اطلاعات جاری منتشره در بازار هم باشد سطح کارایی نیمه قوی و اگر  $\theta_t$  علاوه بر دو مجموعه قبلی شامل اطلاعات نهانی هم باشد، آنگاه سطح کارایی مذکور، سطح قوی خواهد بود. با توجه به تعاریف فوق، دو روش اساسی برای ارزشیابی سهام وجود دارد:

۱. تحلیل تکنیکی؛ که مبتنی بر روند حرکت قیمت سهام در دوره های زمانی مختلف است. در این شیوه تمایلات متغیر سرمایه گذاران در پاسخ به نیروهای مختلف به گونه ای دائمی در قیمت های سهام یا سایر دارائیهای مالی نمود می یابد. در واقع استفاده از قیمت های تاریخی برای پیش بینی قیمت های آینده از این شیوه تحلیلی سرچشمه

می گیرد. این روش تحلیلی در تضاد با فرضیه کارای بازار سرمایه در شکل ضعیف آن می باشد.

۲. تحلیل بنیادین؛ که مبتنی بر تحلیل کارایی و سود دهی شرکت با دیدگاهی از درون است و منجر به کشف قیمت ذاتی سهام می گردد. تحلیلگران بنیادین معتقد به امکان کسب بازده اقتصادی با استفاده از اطلاعات تاریخی و اطلاعات جاری منتشره در بازار در مورد وضع شرکت، شرایط بازار، شرایط صنعت مرتبط و سایر عوامل محیطی موثر بر قیمت دارایی مالی هستند. در این روش از شیوه های متنوعی برای ارزیابی قیمت سهام یا هر نوع دارایی مالی (مثل روش های رگرسیونی، تحلیل روند صورت های مالی، درخت تصمیم گیری، مدل های مبتنی بر سود تقسیمی و سایر مدهای ارزیابی سهام مانند مدل P/E و مدل تنزیل سود تقسیمی همینطور مدل تحلیل و تنزیل جریان های نقدی) استفاده می شود. سطح نیمه قوی کارایی بازار در تضاد با تحلیل بنیادین قرار دارد. در بسیاری از مسائل دنیای واقعی مثل رشته مالی، شبکه های عصبی مصنوعی تفوق خود بر روشهای آماری رگرسیونی چند گانه در تحلیل داده ها را به منصفه ظهور رسانده اند. این شبکه ها توانایی منحصر به فردی در یافتن ارتباط میان ورودی و خروجی خود (با استفاده از مجموعه داده ای مشخصی) بدون نیاز به اطلاعات یا مفروضات تفصیلی دارند.

## ضرورت و ویژگی های مقاله

مقاله حاضر مبتنی بر ترکیب شبکه های عصبی برای دستیابی به سطح بالاتری از صحت بر آورد ها می باشد. انتظار ما این است که بتوانیم نتایج حاصل را با دستیابی به نقطه حداقل متفاوتی در سطح فضای خطا بهبود بخشیم. از معروف ترین روش های ترکیب در شبکه های عصبی مصنوعی، روش های ترکیبی حداقل، حداکثر، میانگین و اکثریت آرا به عنوان روش های ترکیبی غیر آموزش پذیر و روش پیشنهادی وولپرت و شبکه ترکیبی آموزش پذیر اصلاح شده را به عنوان روش های ترکیبی آموزش پذیر می توان نام برد. همانطور که پیش تر آمد استفاده از داده های قیمتی برای پیش بینی روند آتی

مطالعه موردی، نشان دادن نتایج حاصل از الگو و اثبات کارایی آن خواهد بود و مانند روش‌های آماری نیاز به بررسی حداقل ۳۰ نمونه<sup>۵</sup> در اینجا مفهوم نخواهد داشت. نتایج حاصل نیز (چه در مورد شاخص یا یک سهم منفرد) قابل استناد و معتبر خواهد بود. تحقیقات داخلی و بین‌المللی الگوهای مختلفی از شبکه‌های عصبی ساده مثل پرسپترون‌های چند لایه (در داخل و خارج از کشور) و شبکه‌های پیچیده تر مثل شبکه‌های ترکیبی (در خارج از کشور) برای پیش‌بینی قیمت سهام پیشنهاد نموده‌اند، اما این برای اولین بار است که یک مدل ترکیبی آموزش‌پذیر (اصلاح شده) برای پیش‌بینی قیمت سهام ارائه می‌شود. علاوه بر ارائه این الگو، یک معیار رد صلاحیت برای خروجی شبکه ارائه شده است تا آستانه‌ای بهینه برای رد یا قبول صلاحیت خروجی حاصل از شبکه به منظور کاربردی تر کردن نتایج در اختیار قرار داده شود.

### روش شناسی شبکه‌های عصبی

همانطور که ذکر شد نمونه‌های زیادی از پیش‌بینی با استفاده از شبکه‌های عصبی و با استفاده از الگوریتم پس انتشار خطا در جهت تحلیل بازارهای مالی در دنیا وجود دارد. آنچه در میان همه این تحقیقات مشترک است توانایی شبکه ساده پرسپترون چند لایه (که دارای لایه میانی بین لایه ورودی و خروجی باشد) در حل مسائل پیچیده غیر خطی است. لازم به ذکر است وجود لایه میانی در اینجا نقش تعیین‌کننده‌ای در حل مسائل غیر خطی دارد. همچنین وجود یک یا دو لایه میانی (پنهان) نقش موثری در همگرایی مناسب شبکه و دستیابی سریعتر به حداقل مقدار خطا دارد، زیرا وجود دو لایه درونی امکان مدیریت بهتر شبکه را فراهم می‌آورد. بطوریکه لایه اول نقش استخراج ویژگی‌های محلی داده‌ها<sup>۶</sup> و لایه دوم نقش استخراج ویژگی‌های سراسری داده‌ها<sup>۷</sup> را بر عهده خواهد داشت، علاوه بر این حل مسائلی (مانند مسائل مرتبط با سینماتیک معکوس در

قیمت سهام برگرفته از نشانگرهای<sup>۱</sup> روش تکنیکی تحلیل قیمت در بورس اوراق بهادار است. تحقیقات و مقالات بسیاری در مجلات طراز اول دنیا انجام شده‌اند که عامل قیمت را به عنوان ورودی خود در نظر گرفته و از الگوریتمهای پس انتشار خطا استفاده نموده‌اند<sup>۲</sup>. دلایل استفاده از قیمت را می‌توان این‌گونه برشمرد؛ حداقل هر سه ماه یکبار یک گزارش مالی از شرکت‌های پذیرفته شده در بورس منتشر می‌شود که برای تحلیل وضعیت سهام یا هر دارایی مالی در کوتاه مدت کافی نخواهد بود. علاوه بر این به دلیل عدم اطمینانی<sup>۳</sup> بالایی که در بورس اوراق بهادار ایران وجود دارد، اکثر سهامداران به سوداگری برای کسب بازده کوتاه مدت تمایل زیادی دارند. به علت وجود نوسانات روزانه در بورس اوراق بهادار استفاده از روش‌های پیش‌بینی کوتاه مدت علمی<sup>۴</sup> برون رفتی مناسب از آشفتگی‌های کوتاه مدت بازار فراهم می‌آورد. بنابراین در این مقاله روشی متفاوت و ساختاری متفاوت از شبکه‌های عصبی مصنوعی بکار گرفته می‌شود تا بتواند روش‌های قبلی استفاده شده در مقالات را بهبود بخشد. نکته مهمی که در اینجا باید به آن پرداخته شود تفاوت در ویژگی‌های الگوهای آماری با الگوهای مبتنی بر شبکه‌های عصبی است؛ در واقع دلیل عدم نیاز به وجود تعداد زیاد نمونه‌ها در شبکه‌های عصبی این است که این روش مبتنی بر نمونه‌گیری نمی‌باشد ما الگوی بدست آمده را بر روی یک مجموعه داده‌ای اعمال می‌کنیم که همبسته نیستند و نیازی هم به تشریح جزئیات مستتر در آنها نیست. در مقابل الگوهای آماری نیاز دارند که ورودی‌هایشان هم بسته و دارای ارتباط باشد و پیش از ورود به الگو به تفصیل جزئیات و خصوصیات آن‌ها مشخص شده باشد. بنابراین در الگوی شبکه‌های عصبی، هدف از یک

1. Indicators

2. (Lowe, 1994, 3623-3628), (Baba & Kozaki, 1992, 371-377), (Disornetiwat & Dagli, 200, 477-480), (Baba & Handa, 1995, 62-68), (Abdullah & Ganapathy, 2000, 157-161), (Yao & et al., 1999, 221-241), (Kamijio & Tanigawa, 1990, 215-221), (Chenoweth & et al., 1995, 111-115), (Jang & et al., 1991, 42-51), (Atya & et al., 1997, 2112-2115), (Smith & Gupta, 2001, 188-244), (Kamruzaman & et al., 2006, 64-152).

۳. عدم اطمینان (Uncertainty) در مقابل مفهوم ریسک (Risk) است که قابلیت مدیریت شدن را دارد.

۴. در مقابل روش‌های علمی ابتکاری (Heuristic) تحلیل سهام، تحلیل تکنیکی با توانایی هایش و عدم مبتنی بودن بر یافته‌های علمی قرار دارد.

۵. به منظور ناریب بودن برآورد توزیع نمونه‌ای حداقل ۳۰ نمونه در برآورد‌های آماری مورد استفاده قرار می‌گیرد.

6. Local feature extractor


7. Global feature extractor

فیزیک، مکانیک، برق و الکترونیک) که به توابع ناپیوسته در نورون ها نیاز دارد نیازمند وجود دو لایه پنهان است (Haykin, 1999, 213). در تحقیق ما تابع مورد استفاده در لایه میانی از نوع تابع غیر خطی تانژانت هیپربولیک<sup>۱</sup> و تابع مورد استفاده در لایه بیرونی یک تابع لگاریتم سیگموئید خواهد بود<sup>۲</sup>. یکی از نقاط برجسته الگوی پرسپترون های چند لایه توان آن در ارائه سطوح تصمیم غیر خطی است. از این به بعد هر گاه به پرسپترون های چند لایه اشاره می کنیم، شبکه ای بازگشتی با الگوریتم پس انتشار خطا مد نظر است. در شکل (۴) نمای رایج از یک شبکه پرسپترون چند لایه با نورون های تماماً بهم مرتبط نشان داده شده است. هر ساختار پرسپترونی چند لایه نیاز هایی اساسی دارد که عبارتند از:

۱. ابعاد ماتریسی (سطری یا ستونی) برای ورودی ها و خروجی ها<sup>۳</sup> برابر باشد.
۲. ابعاد ماتریسی (سطری یا ستونی) لایه های پنهان<sup>۴</sup> کوچکتر از ابعاد ماتریسی ورودی ها و خروجی ها باشد.
۳. نورون های شبکه کاملاً با هم مرتبط باشند (تا تمام سطوح و احجام داده ای مورد روبش قرار گیرد)

شکل ۴. ساختار شبکه عصبی پرسپترون چند لایه

الگوریتم پس انتشار طبق قاعده دلتا<sup>۵</sup> عمل می کند. در قاعده دلتا، تعدیلاتی که در مورد وزنها صورت می گیرد به گونه ای است که اختلاف بین خروجی مطلوب و خروجی واقعی کاهش می یابد. یعنی اگر مقدار ورودی  $X_i$  منفی باشد، وزن افزایش می یابد و برعکس اگر  $X_i$  مثبت باشد، مقدار وزن کاهش می یابد. در یک شبکه با الگوریتم پس انتشار خطا دو حرکت در امتداد نورون ها در حال وقوع است؛ یک حرکت رو به جلو که داده های ورودی در لایه های شبکه به پیش می روند و یک حرکت برگشتی که ناشی از خطای برگشتی به لایه های قبلی برای تصحیح وزن های سیناپسی است. در جدول ۱ گام های اساسی برای کاهش تصادفی شیب منحنی خطا در الگوریتم پس انتشار ارائه شده است. در اینجا ما عامل  $\delta_h$  را معرفی می نماییم. در واقع مقادیر مورد نظر تنها برای خروجی اصلی شبکه در نظر گرفته می شوند نه نسبت به خروجی هر لایه. بنابراین مجموع خطای یعنی  $\delta_h$  ناشی از هر خروجی متصل به لایه پنهان  $h$  مورد محاسبه قرار می گیرد<sup>۶</sup>. تعداد کل خطاهای یک شبکه پیش رونده به همان اندازه تعداد واحد های خروجی است (یکی برای هر خروجی). به بیان صریح هر وزن در رابطه (۱) درجه پاسخگویی لایه میانی  $h$  برای خطای رخ داده در خروجی  $k$  را نشان می دهد. الگوریتم مورد نظر می تواند به یک تفسیر استاندارد از فرآیند کاهش شیب در الگوریتم پس انتشار خطا تبدیل شود. در صورتی که شیب بصورت رابطه (۲) باشد؛  $n$  شماره داده آموزش شبکه،  $O$  خروجی شبکه،  $k$  شماره لایه خروجی و  $t$  خروجی مورد انتظار است. معمولاً  $\delta_h$  بر تعداد داده های آموزش تقسیم می شود تا با تعیین خطای کلی شبکه، وزن های سیناپسی شبکه را به هنگام نماید.



۱. غیر خطی است تا بتواند روابط غیر خطی پنهان در داده ها را کشف کند و تانژانتی است زیرا نوسان تابع در بازه  $[-1, +1]$  در نتایج حاصل اهمیت دارد  
 ۲. تا منجر به همگرایی نتایج حاصل و رسیدن به جوابهایی در محدوده  $[0, +1]$  شود.

3. Input / Output layers Size = m  
 4. Hidden layers size = M

$$\delta_h = o_h (1 - o_h) \sum_{k \text{ outputs}} w_{kh} \delta_k \quad (1)$$

$$\delta_k = \sum_{n \text{ patterns}} o_{nk} (1 - o_{nk}) (t_{nk} - o_{nk}) \quad (2)$$

5. Delta rule

۶. بجای محاسبه  $(t_k - o_k)$  که به معنی محاسبه تفاضل مقدار خروجی بدست آمده از هر لایه نسبت به خروجی مورد انتظار هر لایه  $(t_k)$  است.

## شبکه‌های عصبی ترکیبی

ترکیب از جمله روشهای بالا بردن کارایی در زمینه طبقه بندی مسائل پیچیده است. پیچیدگی می تواند ناشی از بالا بودن بعد ماتریسی ویژگی ها، محدود بودن تعداد نمونه ها، همپوشانی طبقه ها و وجود آشفتگی قابل ملاحظه در نمونه ها باشد. در هر الگوی ترکیبی می بایست یک سری نیاز های اساسی برآورده شود. این نیازها عبارتند از:

الف) طبقه بند ها کارایی قابل قبول<sup>۱</sup> و استقلال در طبقه بندی داشته باشند. بنابراین کاهش همبستگی<sup>۲</sup> بین طبقه بند ها بسیار مهم است.

ب) وجود یک چارچوب ریاضی مناسب<sup>۳</sup> به منظور استفاده از نقاط قوت طبقه بند ها و خودداری از نقاط ضعف آنها.

## انواع شبکه‌های عصبی ترکیبی

از دیدگاه آموزشی شبکه های عصبی ترکیبی بطور کلی به دو بخش آموزش پذیر و غیر آموزش پذیر تقسیم می شوند.

در شبکه های عصبی ترکیبی غیر آموزش پذیر خروجیهای طبقه بند های پایه<sup>۴</sup> طبق یک قانون ثابت با همدیگر ترکیب می شوند. مثل روش های ترکیبی حداقل، حدکثر، میانگین و اکثریت آراء که شرح مختصر آن ها در زیر می آید:

- روش میانگین<sup>۵</sup>

در این روش تصمیم نهایی از محاسبه میانگین خروجی طبقه بند های پایه<sup>۶</sup> بدست می آید.

## جدول ۱: مراحل کاهش شیب در الگوریتم پس انتشار خطا

ابتدا تمام وزن های شبکه را بصورت مقادیر کوچک تصادفی در نظر بگیرید. تا شرایط خاتمه الگوریتم عمل زیر را انجام دهید:

در هر آموزش خواهیم داشت:

ورودی را مستقیماً به درون شبکه انتشار دهید. و خروجیهای مورد نظر را محاسبه نمایید.

خطا ها را به شکل زیر در جهت معکوس ورودی ها پس انتشار دهید. برای هر خروجی  $k$  عبارت خطا را محاسبه نمایید:

$$\delta_k = o_k(1 - o_k)(t_k - o_k)$$

عبارت خطا را برای هر لایه میانی (پنهان)  $h$  بصورت زیر محاسبه نمایید:

$$\delta_h = o_h(1 - o_h) \sum_{k \text{ outputs}} w_{kh} \delta_k$$

در پایان تمام وزن های را به هنگام کنید بصورتیکه:

$$w_{ji} = w_{ji} \Delta w_{ji} \quad \Delta w_{ji} = -\eta \cdot \delta_j \cdot x_{ji}$$

و اشاره گر  $ij$  یعنی از لایه  $i$  به لایه  $j$ .

۱. دلیل ارائه نتایج طبقه بند های پرسپترون چند لایه به عنوان نتایج ابتدایی در این تحقیق، اثبات کارایی

آنها است

۴. منظور از طبقه بندهای پایه همان طبقه بند های سطح صفر است.

5. Mean method

6. Classifiers

2. Correlation Reduction

۳. منظور چارچوب نظری الگو های ترکیبی ارائه شده متشکل از طبقه بند های منفرد است



شبکه عصبی ترکیبی آموزش پذیر شبکه ای است ترکیبی که تحت نظارت با استفاده از اطلاعات خروجی مورد نظر و تصحیح وزن داده های ورودی، شبکه را آموزش می دهد. معروفترین شبکه عصبی ترکیبی آموزش پذیر برای اولین بار توسط وولپرت معرفی گردید. در این ساختار لایه اول (سطح صفر) شامل طبقه بند های پایه است که توسط مجموعه داده های آموزش در مرحله یادگیری آموزش می بینند. در لایه دوم (سطح یک) یک نگاشت<sup>۴</sup> از فضای خروجی طبقه بند های پایه به خروجی مطلوب<sup>۵</sup> صورت می گیرد. این نگاشت توسط یک شبکه عصبی پرسپترون صورت می گیرد. یادگیری در این لایه به مفهوم تعیین تابع نگاشت دهنده است. این ساختار در شکل (۵) آمده است.

### - روش حداقل<sup>۱</sup>

در این روش نتیجه نهایی از بیشترین مقدار حداقل های بدست آمده از طبقه بند های پایه بدست می آید.


### - روش حداکثر<sup>۲</sup>

در این روش نتیجه نهایی از بیشترین مقدار حداکثر های بدست آمده از طبقه بند های پایه بدست می آید.

### - روش اکثریت آرا<sup>۳</sup>

در این روش خروجی نهایی از طریق خروجی هایی که بیشترین تعداد (رای) را در میان طبقه بند های پایه بدست آورده اند، حاصل می شود.

شکل ۵. نمودار کلی شبکه عصبی آموزش پذیر مبتنی بر روش پیشنهادی وولپرت



۴. عمل تطبیق دادن ورودی ها با خروجی های مورد انتظار که منجر به یادگیری می شود (Mapping)

۵. Target output

1. Minimum method  
2. Maximum method  
3. Majority Vote method

### نتایج تجربی و تشریح مطالب

در این تحقیق مجموعه ای از داده ها به صورت سری های زمانی تأخیری به عنوان ورودی به سیستم داده می شود. این داده ها با استفاده از قیمت پایانی روز مرتب شده اند. این قیمت های پایانی توسط فرمولی که در رابطه (۳) توضیح داده شده محاسبه میشوند<sup>۲</sup>. هدف ما از پیش بینی روند قیمت سهام با استفاده از شبکه های عصبی یافتن قاعده مندی های غیر خطی مؤثر بر قیمت سهام است (به عبارت دیگر یافتن روابط پنهان میان قیمت های گذشته و آینده سهام). زیرا ناتوانی در کشف این روابط غیر خطی در روش های آماری موجود، ضعف خود را در ارزیابی دقیق از کارایی بازار نشان خواهد داد (Timmermann & Granger, 2004, 15-27). همانطور که پیش تر ذکر شد از قیمت تعدیل شده پایانی روز برای آموزش شبکه استفاده می شود.

$$P_2 = P_1 + \left[ (\bar{P}_2 - P_1) * \frac{N}{M} \right] \text{ اگر } \begin{cases} \frac{N}{M} \geq 1 & 1 \\ \frac{N}{M} < 1 & \frac{N}{M} \end{cases} \quad (3)$$

$P_2$  = قیمت بسته شدن امروز

$\bar{P}_2$  = میانگین موزون قیمت امروز

$P_1$  = قیمت بسته شدن دیروز

$N$  = تعداد سهام معامله شده امروز

$M$  = حجم مینا؛ تعداد سهام شرکت که لازم است در طی یک


سال معامله شود

$M=250$  روز کاری / حداقل ۲۰ درصد سهام شناور آزاد

### شبکه عصبی ترکیبی آموزش پذیر اصلاح شده<sup>۱</sup>

در واقع روش پیشنهادی وولپرت را می توان از دسته میانگین وزن دار به حساب آورد. در مرحله آموزش، طبقه بند سطح یک که نقش نگاشت از فضای خروجی طبقه بندهای پایه به خروجی مطلوب را بر عهده دارد، وزنه های مناسب را برای ترکیب مناسب خروجی طبقه بندهای پایه یاد می گیرد. در مرحله آزمون با توجه به مقادیر خروجی طبقه بندهای پایه و با شناختی که از رفتار این طبقه بند ها از مرحله آموزش بدست آمده، وزن مناسبی به هر یک از خروجی های طبقه بندهای پایه داده می شود، اما طبقه بندهای پایه دارای نقاط ضعف و قوت متفاوتی هستند و هرکدام در کاوش بخشی از ویژگی های مسئله تبحر یافته اند و درجه این نقاط ضعف و قدرت برای حل مسائل مختلف متفاوت است. بنابراین در روش پیشنهادی این مقاله، تحت عنوان "شبکه عصبی ترکیبی آموزش پذیر اصلاح شده"، طبقه بند سطح یک، یا به عبارت دیگر ترکیب کننده، علاوه بر اینکه با مقادیر خروجی طبقه بندهای پایه تغذیه می شود، همزمان با داده های ورودی اعمال شده به طبقه بندهای پایه هم تغذیه می شود. به این ترتیب در مرحله آموزش، طبقه بند سطح یک با دیدن همزمان ورودی طبقه بند های پایه (ورودی اولیه) و خروجی طبقه بندهای پایه و دانستن خروجی مطلوب (مورد انتظار)، تقسیم بهینه فضای مسئله را برای هر یک از طبقه بندها، متناسب با نقاط قوت و ضعفشان، از زیر فضاهای متفاوت مسئله یاد می گیرد. سپس در مرحله آزمون طبقه بند سطح یک با دیدن همزمان ورودی و خروجی طبقه بندهای پایه، متناسب با نقاط قوت و ضعف هر یک از این طبقه بند ها، وزن مناسب را بر هر یک از خروجی های طبقه بند های پایه اعمال می کند. این ساختار در شکل (۶) نشان داده شده است.

### شکل ۶. نمودار کلی شبکه عصبی آموزش پذیر اصلاح شده




۲. به دلیل محدودیت سقف و کف نوسان قیمت (نوسان ۳ درصدی) که تابعی از حجم معامله شده در روز

خواهد بود

عصبی در تحقیق حاضر مورد بررسی قرار می گیرد. دوره زمانی مورد استفاده در این تحقیق عبارتست از: ۷ فروردین ۱۳۷۹ تا ۷ فروردین ۱۳۸۴ (۲۶ مارس ۲۰۰۰ تا ۲۶ مارس ۲۰۰۵) به عنوان مجموعه داده های آموزش<sup>۲</sup> و ۸ فروردین ۱۳۸۴ تا ۲۸ اسفند ۱۳۸۵ (۲۷ مارس ۲۰۰۵ تا ۱۹ مارس ۲۰۰۷) به عنوان مجموعه داده های آزمون شبکه<sup>۳</sup>، (شکل ۷). همانطور که پیشتر آمد از قیمت های تعدیلی به عنوان داده های ورودی (X های) شبکه به شکل پنجره ای متحرک از داده ها که به صورت رابطه (۴) محاسبه شده، استفاده می گردد. دلیل استفاده از یک پنجره متحرک افزایش قدرت پیش بینی با توجه به تغییرات سریع قیمت سهام است.

داده های لازم برای آموزش شبکه از تبدیل قیمت های پایانی به صورت پنجره ای متحرک (توالی پیش رونده) از قیمت های روزانه بدست می آید. سپس شبکه آموزش دیده برای پیش بینی روند آتی قیمت سهام مورد نظر بکار می رود. دلیل استفاده از روش آموزش با داده های پنجره ای متحرک، سازگاری با ماهیت پویای قیمت سهام است. عدم رعایت این امر می تواند عامل شکست یک الگوی ایستا در ارائه یک پیش بینی موفق باشد (Tsang & et al., 2007, 453\_467). به این ترتیب خواهیم توانست یک سیستم پشتیبان تصمیم گیری برای معاملات کوتاه مدت در بورس اوراق بهادار برنامه ریزی نماییم<sup>۱</sup>. پرسپترون چند لایه ای که توسط الگوریتم پس انتشار خطا آموزش دیده است به عنوان الگوی اولیه شبکه

رابطه ۴: پنجره ۶ روزه  $x(t-1)-x(t-2), x(t-2)-x(t-3), x(t-3)-x(t-4), x(t-4)-x(t-5), x(t-5)-x(t-6)$



شکل ۷. دو ناحیه داده ای متشکل از سری های زمانی برای آموزش و آزمون شبکه

2 . Training data set

3 . Test data set

۱ . علاوه بر این واقعیت که سیستم مورد نظر ما برای اهداف بلند مدت طراحی شده است

نکته مهم در ترکیب طبقه بندها، تنوع<sup>۲</sup> آنها در آموختن داده‌های ورودی است. اهمیت وجود تنوع، در فرآیند کاهش همبستگی میان طبقه بندها و در جهت افزایش قدرت پیش‌بینی متجلی می‌شود. بنابراین طبقه بندها قادر خواهند بود نواحی مختلفی از فضای داده‌های ورودی را مستقلاً مورد کاوش قرار دهند و در نتیجه توانایی بهتری در کاهش خطای آموزش و داده‌کاوی در ناحیه‌ای مشخص خواهند داشت. این امر به افزایش کارایی شبکه عصبی ترکیبی در سطح کلی منجر خواهد شد. روش‌های مختلف ایجاد تنوع در طبقه بندها در طی پروسه آموزش عبارتند از: روش‌های تزریق نمونه‌های ورودی به سامانه، تنوع در نمونه‌های مجموعه آموزش، پروسه آموزش و استراتژی‌های آموزش (نظارت بر تعلیم شبکه). در تمام روش‌های ذکر شده مبنای عمل، فنون کاهش همبستگی خواهد بود.

در تحقیق حاضر ۵ طبقه بندی که در بالا تشریح گردیدند به عنوان طبقه بند‌های پایه برای ترکیب روش‌های حداقل، حداکثر، میانگین، اکثریت آراء، روش پیشنهادی وولپرت و روش پیشنهادی این مقاله<sup>۳</sup> مورد استفاده قرار گرفتند. نتایج حاصل با استفاده از ۴۴۷ داده قیمتی روزانه، به عنوان داده‌های مجموعه آزمون، در جدول شماره (۳) آمده است. لازم به ذکر است پس از تجربیات مختلف شبکه‌ای با جانمایی ۱۱:۷:۲ به عنوان ساختار طبقه بند سطح یک مناسب تشخیص داده شد.

روش ترکیب	حداقل	حداکثر	میانگین	اکثریت آراء	روش وولپرت	روش پیشنهادی
درصد پیش‌بینی	۶۹/۶۰۷۸	۷۰/۵۸۸۲	۷۳/۸۵۶۲	۷۳/۲۰۲۶	۷۵/۴۹۰۱	۷۶/۳۱۰۵

همانطور که در جدول شماره (۳) دیده می‌شود، ترکیب طبقه بندهای پایه "به روش پیشنهادی" این مقاله یعنی شبکه عصبی ترکیبی آموزش پذیر اصلاح شده، نسبت به

در مقابل، خروجی‌های شبکه عصبی رمزگذاری شده اند تا پیش‌بینی روند آتی قیمت سهام پتروشیمی خارگ را نمایش دهند. سمت و سوی روند به دو طبقه روند افزایشی و روند کاهشی تقسیم بندی شده است. خروجی مورد نظر برای روند افزایشی و روند کاهشی به ترتیب عبارتست از  $\begin{bmatrix} 1 \\ 0 \end{bmatrix}$  و  $\begin{bmatrix} 0 \\ 1 \end{bmatrix}$ . خروجی مورد انتظار همزمان با

تزریق داده‌های ورودی، به سیستم داده می‌شود تا شبکه آموزش ببیند. الگوی مورد نظر طی یک فرآیند آزمایش و خطا آموزش داده می‌شود و سپس مورد آزمون قرار می‌گیرد تا ساختار مناسب برای شبکه انتخاب گردد. پس از تجربیات مختلف ساختار شبکه‌ای با دو لایه پنهان مناسب تشخیص داده می‌شود. طرح و جانمایی شبکه عصبی پرسپترون چند لایه‌ای که در این تحقیق مورد هیبربولیک در لایه‌های پنهان و تابع لگاریتم سیگموئید در لایه خروجی ارائه می‌شود. شبکه پرسپترون چند لایه در این تحقیق با استفاده از مجموعه داده‌ای به شکل پنجره متحرک آموزش می‌بیند. در اینجا نمونه‌های آزمون در زمان  $t$  با  $P_t$  نشان داده می‌شود و نمونه‌ها برای پنجره آموزش با ابعاد ماتریس سطری  $m$  عبارتند از  $P_{t-m}$  تا  $P_{t-1}$ . در مطالعه ما اندازه ماتریسی پنجره  $1 \times 6$  می‌باشد. به هنگام آموزش شبکه، پنجره متحرک شش روزه، یک به یک، در امتداد نمونه‌های آموزش به جلو حرکت می‌کند. در این تحقیق شبکه مورد نظرمان را ۵ بار و هر بار با وزن‌های اولیه تصادفی متفاوتی آموزش می‌دهیم تا نتایج با پایایی بیشتری ارائه شود. سپس هر شبکه به وسیله داده‌های آزمون مورد آزمایش قرار می‌گیرد. نتایج این آزمون در جدول شماره (۲) آمده است:

شماره طبقه بند	۱	۲	۳	۴	۵
درصد پیش‌بینی	۷۰/۲۶۱۴	۶۹/۶۰۷۸	۷۰/۵۸۸۲	۷۰/۲۶۱۴	۷۰/۵۸۸۲

این الگو به مفهوم خرید دارایی مالی در انتظار افزایش قیمت دارایی مورد نظر می باشد. همینطور علامت فروش بدست آمده به مفهوم فروش دارایی مالی در انتظار کاهش قیمت دارایی مورد نظر خواهد بود. پروسه فیلترکردن که شرح آن در زیر می آید پیش از اتخاذ تصمیم با استفاده از خروجی الگو صورت می گیرد و علائم خرید و فروشی که قانون فیلتر مورد نظر را برآورده نسازند حذف خواهند شد.

### پروسه فیلترکردن<sup>۶</sup>

همانطور که در بالا توضیح داده شد، دو حداقل مجاز، با مقدار متناسب با خروجی، برای افزایش اطمینان علائم نهایی افزایشی یا کاهشی مورد استفاده قرار می گیرد. در صورتی که مقدار بدست آمده از خروجی شبکه در طبقه ۱ از مقدار بدست آمده در طبقه ۲ بیشتر باشد و مقدار اختلاف این دو مقدار بیشتر از  $\beta_1$  باشد، آنگاه علامت خرید بدست آمده قابل اطمینان خواهد بود. همینطور اگر خروجی حاصل از طبقه ۲ بزرگتر از خروجی حاصل از طبقه ۱ باشد و مقدار اختلاف این دو مقدار بیشتر از  $\beta_2$  باشد، آنگاه علامت فروش بدست آمده قابل اطمینان خواهد بود. نتایج عملی حاصل از این فیلترکردن در جدول (۴) آمده است.

روش ترکیب	$\beta_1$	$\beta_2$	تعداد نمونه های رد صلاحیت شده	درصد پیش بینی
حداقل	۰/۵۷۰۴	۰/۴۴۵۴	۵۷	۷۱/۸۸۷۶
حداکثر	۰/۵۷۰۴	۰/۴۴۵۴	۵۶	۷۲/۸۰۰۰
میانگین	۰/۵۷۰۴	۰/۴۴۵۴	۱۸۵	۸۲/۶۴۴۶
اکثریت آراء	۲/۸۵۲۲	۲/۲۲۷۱	۱۸۵	۸۲/۶۴۴۶
روش وولپرت	۰/۹۸۵۲	۰/۵۳۳۲	۸۳	۸۳/۱۴۶۷
روش پیشنهادی	۰/۶۸۹۲	۰/۵۸۹۱	۹۵	۸۵/۲۰۱۹

نتایج ذکر شده در جدول (۴) نشان می دهد که چگونه در پروسه فیلترکردن در صورتی که اختلاف خروجی حاصل از دو طبقه نتواند حداقل مجاز (مقدار آستانه ای) بدست آمده را ارضاء کند، منجر به حذف خروجی مورد نظر خواهد شد.

روش های ترکیبی دیگر و حتی روش پیشنهادی وولپرت عملکرد بهتری نشان می دهد. ابتکار دیگر این تحقیق این است که به منظور بهبود نتایج حاصل از ترکیب طبقه بند ها، معیاری به نام « معیار رد صلاحیت<sup>۱</sup> » در نظر گرفته می شود تا نتایج حاصل، از قدرت کاربرد و اعتماد بیشتری در اجرا برخوردار باشند.

### تعریف معیار رد صلاحیت

بدلیل وجود طیف متنوعی از قاطعیت در پیش بینی ها از یک آستانه یا حداقل مجاز برای افزایش قاطعیت تصمیمات مبتنی بر خروجی مدل استفاده می شود. در رابطه (۵) و رابطه (۶) روش رسیدن به این مقدار آستانه ای ذکر شده است:

$$\beta_1 = \frac{1}{N_1} = \sum_{i=1}^{N_1} (O_{n1i} - O_{n2i}) \quad (5)$$

$$\beta_2 = \frac{1}{N_2} = \sum_{i=1}^{N_2} (O_{n2i} - O_{n1i}) \quad (6)$$

در این جا  $\beta_1$  و  $\beta_2$  آستانه (حداقل مجاز) برای خروجی های حاصل از شبکه به ترتیب با فرمان خرید<sup>۲</sup> و فرمان فروش<sup>۳</sup> می باشند. در صورتیکه تفاضل مقدار بدست آمده برای خروجی طبقه ۱ و خروجی طبقه ۲ در دو حالت فوق از این اعداد کمتر باشد، این خروجی نامطمئن شناخته می شود و خود به خود حذف خواهد شد.

در این دو رابطه  $O_{n2i}$  و  $O_{n1i}$  به ترتیب بیانگر خروجی طبقه ۱ و خروجی طبقه ۲ می باشند. همینطور  $N_1$  و  $N_2$  به ترتیب تعداد نمونه های مجموعه آموزش در روند افزایشی قیمت و روند کاهش قیمت است. در فاز آزمون، خروجی های الگوی طبقه بندی، پیش از اتخاذ تصمیم نهایی از فیلتر « مقیاس اطمینان<sup>۴</sup> » شرح داده شده در بالا خواهد گذشت. علامت<sup>۵</sup> خرید بدست آمده از خروجی

1. Rejection Criterion

۲. که منجر به پیروزی طبقه ۱،  $\begin{bmatrix} 1 \\ 0 \end{bmatrix}$  می شود  
 ۳. که منجر به پیروزی طبقه ۲،  $\begin{bmatrix} 0 \\ 1 \end{bmatrix}$  می شود

4. Confidence Measure

5. Signal

6. Filter Procedure

## نتیجه گیری

در تحقیقات گذشته در زمینه پیش بینی روند قیمت، چه در مورد سهام یا شاخص سهام از شبکه های عصبی منفرد و ساده استفاده شده است. گرچه چنین نتایجی در آن زمان یک انقلاب در زمینه پیش بینی به شمار می رفت، اما با توسعه روش های پیش بینی ابتکاری مبتنی بر الگوریتم های هوش مصنوعی، نتایج ذکر شده اکنون چندان رضایت بخش به نظر نمی رسند. در این تحقیق سعی شده تا با پیشنهاد الگویی آموزش پذیر از شبکه های عصبی ترکیبی و استفاده از مقیاس اطمینان، نتایج پیش بینی روند قیمت با استفاده از شبکه های عصبی بهبود یابد. در این روش داده های آموزش تحت نظارت داده های آزمون طبقه بند های پایه را آموزش داده اند، سپس یک شبکه در سطح بالاتر با دیدن همزمان خروجی

طبقه بند های پایه و داده های آموزش پیش بینی خود را بر اساس قدرت و ضعف طبقه بند های پایه در شیب های مختلف تابع خطا ارائه می کند. با توجه به نتایج، بهترین الگوی ارائه شده در این تحقیق الگوی ترکیبی آموزش پذیر اصلاح شده با صحت پیش بینی تا ۸۵/۲۰۱۹ درصد می باشد. نتیجه بدست آمده یک حد نصاب جدید پس از الگوی آموزش پذیر وولپرت<sup>۱</sup> است که در تحقیقات قبلی (Nikoo & et al., 2007, 287-293) حاصل شد. این الگو می تواند به عنوان یک ابزار کمکی در کنار تحلیل بنیادین قیمت سهام و به عنوان یک روش پیش روند قیمت سهام مورد استفاده قرار گیرد. نکته این که با وجود آمدن الگوهای کاربردی قدرتمند، بورس اوراق بهادار گام مؤثری به سمت کارایی بیشتر بر می دارد (Timmermann & Granger, 2004, 15-27).

## منابع و مأخذ :

۱. راسل، استوارت و پیتر نورویگ « هوش مصنوعی؛ رهیافتی نوین » عین الله جعفر نژاد قمی انتشارات علوم رایانه، تهران، ۱۳۸۳، چاپ دوم.
2. Atya, A, N. Talaat & S. shaheen (1997) "An Efficient Stock Market Forecasting Model Using Neural Networks", International Conference on Neural Network., Volume: 4, 2112-2115
3. Baba N. et al. (1994) "A hybrid algorithm for finding the global minimum of error function of neural networks and its applications", Neural Networks, Vol.7, 1253-1265.
4. Baba N. & M. Kozaki (1992) "An intelligent forecasting system of stock price using neural network", Proceedings of International Joint Conference on Neural Networks, Vol.1, 371-377.
5. Baba N. and H. Handa (1995) "Utilization of Neural Network for Constructing a User Friendly Decision Support System to Deal Stocks, Journal of Simulation & Gaming, Vol.5, No.1, 62-68.
6. Chenoweth, T., Z. Obradovic & et al. (1995) "Technical Trading rules as a Prior Knowledge to a Neural Networks Prediction System for the S&P 500 Index", IEEE Technical Applications Conference and Workshops, Portland, Oregon, 111-115.
7. Disorntetiwat, P. & C.H. Dagli (2000) "Simple ensemble-averaging model based on generalized regression neural network in financial forecasting problems", Adaptive Systems for Signal Processing, Communications, and Control Symposium 2000, AS-SPCC. The IEEE 2000, Vol., Iss., 2000, 477-480

8. Ebrahimpour R., E. Kabir, H. Esteky & M.R. Yousefi (2008) "A Mixture of Multilayer Perceptron Experts Network For Modeling Face/Nonface Recognition in Cortical Face Processing Regions", *Intelligent Automation and Soft Computing*, Elsevier, Vol. 14, No. 2, 145-156.
9. Ebrahimpour R., E. Kabir & M.R. Yousefi, (2008) "View-independent Face Recognition with Mixture of Experts" *Journal of Neurocomputing*, Vol. 71, No. 4-6, Elsevier, (October), 1103-1107.
10. Ebrahimpour R., E. Kabir & M.R. Yousefi, (2008) "Teacher-Directed Learning in View-independent Face Recognition with Mixture of Experts Using Single-view Eigenspaces" *Journal of Franklin Institute*, Vol. 345, No. 2, Elsevier, (June), 87-101.
11. Fama, E. (1970) "Efficient capital markets: a review of theory and empirical work", *Journal of Finance*, Vol. 25, 383-417.
12. Farmer, D. and A. Lo (1999) "Frontiers of Finance: Evolution and Efficient Markets", *Proceedings of the National Academy of Sciences*, Vol. 96, 9991-9992.
13. Fernandez A. & S. Gomez (2005) "Portfolio selection using neural networks", *Journal of Computers & Operation Research*, Vol. 34, (August), Elsevier, 1177-1191.
14. Franke J. M. Klein (1999) "Optimal portfolio management using neural networks; a case study", *University of Kaiserslautern*, (June).
15. Hatami N., R. Ebrahimpour (2007) "Combining Multiple Classifiers: Diversify with Boosting and Combining by Stacking", *International Journal of Computer Science and Network Security (IJCSNS)*, VOL. 7 No. 1, (January), 127-131.
16. Haykin S. (1999) "Neural Networks: A Comprehensive Foundation", Prentice Hall Inc, International Edition, New Jersey, 2<sup>nd</sup> Edition, 1-255.
17. Jang G. S., Lai B. F., Jiang W. & Chien L. H. (1991) "An Intelligent Trend Prediction and Reversal Recognition System Using Dual-Module Neural Networks", *First International Conference on Artificial Intelligence Applications on Wall street*, New York, U.S.A., (October), 42-51.
18. Jensen, M. (1978) "Some anomalous evidence regarding market efficiency", *Journal of Financial Economics*, Vol. 6, 95- 101.
19. Jingtao Yao, Chew Lim Tan & Hean-Lee Poh (1999) "Neural Networks for Technical Analysis: A case study on KLCT", *International Journal of Theoretical and Applied Finance (Quarterly)*, Vol.2, No.2, 221-241.
20. Kamijo, K. & T. Tanigawa (1990) "Stock Price Pattern Recognition: A Recurrent Neural Network Approach", *Proceedings of the International Joint Conference on Neural Networks*, San Diego, 215-221.
21. Kamruzzaman J., R. Begg & R. Sarker (2006) "Artificial Neural Networks in Finance and Manufacturing", *Idea Group Publishing*, U.S.A, 1-163.
22. Karizi, S. H. N., R. Ebrahimpour & E. Kabir (2005) "Usage of combining classifiers in Farsi Handwritten digit recognition", *3rd Iranian Conference on Machine Vision and Image Processing (MVIP2005)*, University of Tehran, Tehran, Iran, (February), 23-24.
23. Ko P.C. & P.C. Lin (2007) "Resource allocation neural network in portfolio selection", *Journal of Expert Systems with Applications*, Vol. xxx, (August), xxx-xxx.
24. Kohavi, R. & F. Provost (1998) "Glossary of terms, *Machine Learning*", Vol. 30, 271-274.
25. Kuncheva L.I. (2004) "Combining Pattern Classifiers; Methods and Algorithms" *John Wiley & Sons, INC.*, Publication, Hoboken, New Jersey.
26. Lin C.M., J.J. Huang, M. Gen & G.H. Tzeng (2006) "Recurrent neural network for dynamic portfolio selection", *Journal of Applied Mathematics and Computation*, Vol. 175, Elsevier, 1139-1146.
27. Lowe D., Novel exploitation of neural network methods in financial markets, *Proceedings of IEEE International Conference on Neural Networks*, 1994, Vol.6, 3623-3628.

28. Nasiri-Avanaki M. R. & R. Ebrahimpour (2007) "In-service video quality measurements in optical fiber links based on neural network", *Neural Network World*, Vol. 16, No. 5, 457-468.
29. Nikoo H., M. Azarpeikan, M.R. Yousefi, R. Ebrahimpour & A. Shahrabadi (2007) "Using A Trainable Neural Network Ensemble for Trend Prediction of Tehran Stock Exchange", *International Journal of Computer Science and Network Security (IJCSNS)*, 2007, VOL.7 No.12, 287-293.
30. Schiewchanwattana S. and C. Lursinsap, (2002) "FI-GEM Networks for Incomplete Time-Series Prediction", *IEEE Proceedings of International Joint Conference on Neural Networks, USA*, 1757-1762.
31. Smith K., Gupta J. (2001) "Neural Networks in Business: Techniques and Applications", Idea Group Publishing, U.S.A. 189-244.
32. Thawornwong S. & D. Enke (2004) "The adaptive selection of financial and economic variables for use with artificial neural networks", *Journal of Neurocomputing*, Vol. 56, Elsevier, 205-232.
33. Thomas Mitchell (1997) "Machine Learning", McGraw-Hill International Edition, New York.
34. Timmermann A. & Clive W.J. Granger (2004) "Efficient market hypothesis and forecasting", *International Journal of Forecasting*, Vol. 20, Elsevier B. V. 15-27.
35. Trippi R. & Turban E. (1993) "Investment management decision support and expert systems", boyd & fraser Publishing Company, Boston (USA).
36. Tsang Philip M., Paul Kwok, S.O. Choy, Reggie Kwan, Ng S.C., Jacky Mak, Jonathan Tsang, Kai Koong & Tak-Lam Wong (2007) "Design and implementation of NN5 for Hong Kong stock price forecasting" *journal of Engineering Applications of Artificial Intelligence*, Vol. 20, Elsevier, (December), 453-361.
37. Windeatt T, R. Ghaderi (1998) "Dynamic Weighting Factors for Decision Combining", *Proc. of IEE Int. Conf. On Data Fusion, Great Malvern, UK, (October)*, 123-130
38. Wolpert (1992) "staked generalization", *Neural Networks*, Vol. 5, No. 2, 241-259.
39. Yu L., S. Wang & K.K. Lai (2008) "Neural Network – based mean – variance – skewness model for portfolio selection", *Journal of Computers & Operation Research*, Vol. 35, Elsevier, (March), 34-46.
40. Zandesh G.R., R. Ebrahimpour, B. Bakherad & N. Karimi Adib (2005) "Optimization the Management of Electrical Power Transmission Network by Neural Networks to Decrease the Corona Loss, Based on ICT", *IEEE/PES Transmission and Distribution conference & Exhibition: Asia and Pacific Dalian, China*.