



پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP و برآورد نقطه بیش از حد توسط شمارش فواصل زمانی: شواهدی از بورس اوراق بهادار

محمد رضا وطن پرست^۱

مسعود اسدی^۲

شعبان محمدی^۳

عباس بابایی^۴

تاریخ دریافت مقاله: ۹۷/۰۸/۲۷ تاریخ پذیرش مقاله: ۹۷/۱۰/۰۵

چکیده

در این پژوهش برای تعیین روش پیش بینی قیمت سهام، یک شبکه عصبی LM-BP بر اساس سری های زمانی با توجه به قیمت باز، بالاترین قیمت، پایین ترین قیمت، قیمت بسته و حجم معاملات ارائه شد. در پژوهش حاضر، ۳۱۵ روز قیمت سهام را برای ایجاد ۱۰ نمونه انتخاب و مجموعه آزمون شامل قیمت سهام از روز ۳۱۶ تا روز ۳۲۰ را انتخاب و از شبکه عصبی LM-BP استفاده شده است. در این پژوهش، تعیین نقطه بحرانی بیش از حد، عدم تقارن و شمارش فواصل زمانی بررسی شد. منحنی MRE2-MRE1 رسم شده و دقت مربوط به بهترین پیش بینی شبکه عصبی BP بر اساس چند تکرار مستقل برآورد شد. پس آزمون نیز به روش آزمون کوپیک و آزمون کریستوفرسون انجام شد. نتایج نشان داد که پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP و برآورد نقطه بیش از حد توسط شمارش فواصل زمانی، نتایج بهتری نسبت به روش های موجود ارائه می دهد.

کلمات کلیدی

پیش بینی قیمت سهام، شبکه عصبی LM-BP، شمارش فواصل زمانی.

۱ استادیار گروه حسابداری، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران. (نویسنده مسئول) vatanparast@iaurasht.ac.ir
۲ دانشجوی دکتری مهندسی مالی، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران. masoud.asadi1383@gmail.com
۳ کارشناسی ارشد حسابداری، دانشکده شهید رجایی، دانشگاه فنی و حرفه‌ای استان خراسان، ایران. Shaban1362@gmail.com
۴ دانشجوی دکتری مهندسی مالی، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران. abbasbabaei9@gmail.com

مقدمه

بازده سرمایه‌گذاری به‌طور مستقیم در تناسب با ریسک است. برای افزایش مقدار سود، ریسک‌های بیشتری ممکن است مدنظر باشد. بنابراین، تحقیق در زمینه عوامل تعیین‌کننده قیمت سهام شرکت‌های بورسی، ارزش سرمایه‌گذاری سهام شرکت و روش‌های پیش‌بینی قیمت سهام یک شرکت، ارزشی کاربردی، مهم و از نظر تئوری معنادار هستند. عوامل مؤثر بر قیمت سهام شامل عوامل خارجی (چرخه اقتصادی، نرخ بهره، نرخ تورم و غیره)، عوامل داخلی (روابط عرضه-تقاضا، سیاست، موضوع سرمایه‌گذاران و غیره) و عوامل شرکتی (کسب‌وکار، دارایی، سرمایه‌گذاری، و غیره) می‌باشند (لی و همکاران، ۲۰۱۳). دو دیدگاه در مورد گرایش‌های تغییر قیمت سهام وجود دارد. تحلیل بنیادی (ادیریسینگ و ژانگ، ۲۰۰۸؛ وانگ و همکاران، ۲۰۱۴) که بیان می‌کند قیمت‌های سهام در هر لحظه به توانایی کسب‌وکار شرکت بستگی دارد (چن، ۲۰۱۵؛ لی و همکاران، ۲۰۱۴). دیدگاه دیگر تحلیل تکنیکی است (لی و همکاران، ۲۰۰۵). فرض اساسی این روش این است که سرمایه‌گذاران همیشه از الگوهای مشابه پیروی می‌کنند. در سال‌های اخیر، به‌طور قابل‌توجهی بازار سهام، در سرمایه، حجم معاملات، تعداد شرکت‌های بورسی و مقدار پول رشد داشته است. (ژانگ و همکاران، ۲۰۱۶). روش‌های معمول پیش‌بینی قیمت سهام روش جعبه جینکینز (جینکینز، ۱۹۹۴؛ کاظم و همکاران، ۲۰۱۳) حاوی مدل خود همبسته^۱ و مدل میانگین متحرک خود همبسته یکپارچه^۲ هست. بازار سهام یک سیستم پویای غیرخطی پیچیده است. در سال‌های اخیر، برای پیش‌بینی قیمت سهام، روش‌های غیرخطی مانند سری زمانی فازی و شبکه‌های عصبی BP، پیشنهاد شده است (وانگ و همکاران، ۲۰۱۱؛ باقری و همکاران، ۲۰۱۴). روش پیش‌بینی قیمت سهام بر اساس سری زمانی فازی سه مرحله دارد. ابتدا، به‌طور کلی گفتمان U، دیوارک U را تعریف می‌کند. سپس مجموعه‌های فازی را بر مبنای گفتمان و اطلاعات فازی تاریخی تعریف می‌کنیم. سپس روابط منطقی فازی و گروه‌ها را تعیین می‌کند. آخرین مرحله، پیش‌بینی قیمت سهام است (چن، ۱۹۹۶؛ یو، ۲۰۰۵). با این حال شبکه‌های عصبی BP در تجزیه و تحلیل اقتصادی مزایای منحصر به فردی دارند (لیو و ما، ۲۰۱۲). پیش‌بینی وقایع و سایر بخش‌های اقتصادی از آن جمله هستند. شبکه‌های عصبی BP به‌طور گسترده‌ای در تجزیه و تحلیل سری و پیش‌بینی به دلیل توانایی قوی آن‌ها برای تقریب عملکرد غیرخطی مورد استفاده قرار می‌گیرند. شبکه‌های عصبی BP توانایی تعریف توابع از طریق فرآیند یادگیری و تعیین وزن و آستانه بین نورون‌ها را دارند. بنابراین، نمی‌توانیم پیش‌بینی‌های آینده قیمت سهام بدون درک پویایی درونی بازار سهام را داشته باشیم. کاربرد شبکه‌های عصبی BP در زمینه‌های

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP /... وطن پرست، اسدی، محمدی و بابایی

هوش مصنوعی در سال های اخیر افزایش یافته است. بسیاری از یافته های تحقیق نشان می دهد که پیش بینی قیمت سهام از طریق شبکه های عصبی BP می تواند سود بیش از حد تولید کند.

مبانی نظری و پیشینه پژوهش

الگوریتم شبکه عصبی LM-BP

شبکه عصبی BP شامل لایه ورودی، پنهان و خروجی است. لایه پنهان می تواند یک یا چند لایه باشد. این فرآیند یادگیری به شرح زیر است: سیگنال ورودی از لایه ورودی به لایه خروجی از طریق لایه های پنهان مختلف منتقل می شود و سیگنال های خروجی در پایانه های خروجی تولید می شوند. در این فرآیند، نورون ها در تمام لایه ها فقط بر وضعیت نورون های زیرین تأثیر می گذارند و وزن و آستانه شبکه بدون تغییر باقی می ماند. اگر خروجی واقعی و سیگنال های خروجی مورد نظر، ناسازگار باشند، سیگنال های خطا از لایه خروجی به لایه قبلی منتقل می شوند. در مرحله خطای پیشبرد خطا، وزن و آستانه شبکه با بازخورد خطا تنظیم می شود تا سیگنال های خروجی واقعی را به سیگنال های خروجی برساند. در این پژوهش، الگوریتم LM-BP برای آموزش شبکه عصبی اتخاذ می شوند زیرا سریع ترین الگوریتم پیشنهاد شده برای آموزش شبکه های عصبی متوسط به شمار می آیند (باتیتی، ۱۳۹۲؛ هاگان و همکاران، ۱۹۹۶). شبکه عصبی BP معمولی سه لایه دارد. همه نمونه های ورودی از مجموعه آموزشی، به شبکه با وزن و آستانه های اولیه تصادفی وارد شبکه می شوند. تعداد سیگنال های ورودی در لایه ورودی s^0 و نماد نورون دلخواه m باشد. لایه پنهان s^1 neurons، و هر نورون توسط i بیان شده است. لایه خروجی دارای نورون های خروجی S^2 است و نورون دلخواه توسط j بیان می شود (باشر و هاجمر، ۲۰۰۰؛ ژانگ و همکاران، ۲۰۰۹). عناصر ماتریس وزن بین ورودی و لایه مخفی توسط $(i = 1, 2, \dots, s^1, m = 1, 2, \dots, s^0)$ و $\omega_{i,m}^1$ و مقدار آستانه دلخواه لایه پنهان را نشان می دهد. عناصر ماتریس وزن بین لایه پنهان و خروجی توسط آن بیان می شود $(j = 1, 2, \dots, s^2)$ و $\omega_{i,j}^1$ و b_j^1 مقدار آستانه دلخواه لایه خروجی است. ورودی های خالص لایه مخفی توسط $n_{i,q}^1$ ، خروجی های لایه پنهان توسط $n_{i,q}^1$ بیان می شوند و ورودی خالص لایه خروجی توسط $n_{i,q}^2$ بیان می شود و خروجی لایه خروجی توسط $n_{i,q}^2$ بیان می شود جایی که نمونه دلخواه توسط $q = (q = 1, 2, 3, \dots, Q)$ بیان شده است. نمونه های آموزشی وارد شبکه عصبی می شوند:

$$a^0 = [a_1^0, a_2^0, \dots, a_q^0] \text{ و } a_q^0 = [a_{1,q}^0, a_{2,q}^0, a_{3,q}^0, \dots, a_{s^0,q}^0]^T \quad (1)$$

خروجی شبکه عصبی:

$$(۲) \quad a^2 = [a_1^2, a_2^2, \dots, a_q^2] \text{ و } a_q^0 = [a_{1,q}^2, a_{2,q}^2, a_{3,q}^2, \dots, a_{s^2,q}^2]^T$$

خروجی موردنظر نمونه‌های آموزشی:

$$(۳) \quad d = [d_1, d_2, \dots, d_Q], \quad d_q = [d_{1,q}, d_{2,q}, \dots, d_{s^2,q}]^T$$

سیگنال‌ها از لایه ورودی به لایه پنهان شروع می‌شوند:

$$n^1 = W^1 \times a^0 + b^{1'}, \quad a^1 = F^1(n^1); \quad (۴)$$

سیگنال‌ها از لایه مخفی به لایه خروجی منتقل می‌شود:

$$n^2 = W^2 \times a^1 + b^{2'}, \quad a^2 = F^2(n^2); \quad (۵)$$

مجموع مربعات خطا از تمام نورون‌ها در لایه خروجی:

$$(۶) \quad e = d - a^2 = (e_{j,q})_{s^2 \times Q} = \begin{bmatrix} e_{1,1} & e_{1,2} & \dots & e_{1,Q} \\ e_{2,1} & e_{2,2} & \dots & e_{2,Q} \\ \vdots & \vdots & \ddots & \vdots \\ e_{s^2,1} & e_{s^2,2} & \dots & e_{s^2,Q} \end{bmatrix}$$

$$error = \sum_{j=1}^{s^2} \sum_{q=1}^Q e_{j,q}^2$$

اگر خطا (error) کمتر از ε باشد^۳ (ε : دقت محاسبه مورد انتظار است) محاسبه خاتمه یابد. در غیر این صورت مرحله پخش پروسه اولیه انجام خواهد شد. الگوریتم LM-BP به‌درستی تنظیم وزن و آستانه با استفاده از ماتریس تقریبی به‌صورت زیر انجام می‌دهد:

$$X(K+1) = X(K) - [J^T \times J + M \times 1]^{-1} \times J^T \times v, \quad (۷)$$

به‌طوری که تعداد تکرار k است هنگامی که μ یک ضریب بزرگ‌تر است، فرمول فوق تقریباً یک الگوریتم کاهش گرادینان با مراحل کوچک‌تر را دربرمی‌گیرد؛ هنگامی که μ یک ضریب کوچک‌تر است، فرمول بالا تقریباً یک روش گاوس-نیوتن است.

$$(۸) \quad x = [x_1 \quad x_2 \quad \dots \quad x_n]^T \\ = [\omega_{1,1}^1 \quad \dots \quad \omega_{s^1,s^0}^1 \quad b_1^1 \quad \dots \quad b_{s^1}^1 \quad \omega_{1,1}^2 \quad \dots \quad \omega_{s^2,s^1}^2 \quad b_1^2 \quad \dots \quad b_{s^2}^2]^T;$$

$$(۹) \quad x = [v_1 \quad v_2 \quad \dots \quad v_N]^T \\ = [e_{1,1} \quad \dots \quad e_{s^2,1} \quad e_{1,2} \quad \dots \quad e_{s^2,2} \quad e_{1,Q} \quad \dots \quad e_{s^2,Q}]^T;$$

$$N = s^2 \times Q; \quad (۱۰)$$

$$n = s^1 \times s^0 + s^1 + s^2 \times s^1 + s^2$$

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP /... وطن پرست، اسدی، محمدی و بابایی

$$= s^1 \times (s^0 + 1) + s^2 \times (s^1 + 1) \quad (11)$$

مشاهدات نرمال گویای نمونه‌های آموزشی در مجموعه آموزشی، برای تفریق مقادیر ثابت از خروجی‌های شبکه عصبی هست. مجموع خطا مربعات را می‌توان با فرمول زیر حل کرد، و خطا ۱، دقت پذیری اندازه‌گیری است.

$$e = d - a^2 = (e_{j,q})_{s^2 \times Q} = \begin{bmatrix} e_{1,1} & e_{1,2} & \dots & e_{1,Q} \\ e_{2,1} & e_{2,2} & \dots & e_{2,Q} \\ \vdots & \vdots & \ddots & \vdots \\ e_{s^2,1} & e_{s^2,2} & \dots & e_{s^2,Q} \end{bmatrix} \quad (12)$$

$$error1 = \sum_{j=1}^{s^2} \sum_{q=1}^Q e_{j,q}^2$$

$$\mu = \begin{cases} \mu \div \theta & error1 < error \\ \mu \times \theta & error1 \geq error \end{cases}; \quad \theta \geq 1. \quad (13)$$

به‌طور کلی، ثابت θ بیش از ۱ است، و مقدار اولیه μ مقداری ثابت بین ۰ و ۱ است. پس از به دست آوردن وزن و آستانه‌های لایه‌های مختلف، اصلاح لازم برای انجام μ صورت گرفته است. سپس، محاسبات به مرحله انتشار اولیه حرکت می‌کند. بدیعی وهم کاران (۱۳۹۶) نشان دادند که مدل شبکه عصبی دارای خطای پایین و قدرت توضیح دهنده بالا و در نتیجه از قدرت پیش‌بینی خوبی برخوردار هست.

روش پیش‌بینی قیمت سهام با سری‌های زمانی بر اساس شبکه عصبی BP

تجزیه و تحلیل سری زمانی یک روش مهم برای مدل‌سازی و پیش‌بینی دستگاه‌های پویای غیرخطی است (سانگجون و همکاران، ۲۰۱۵؛ پریرا و همکاران، ۲۰۱۵). در حال حاضر، روش‌های خطی مانند مدل متوسط متحرک خود همبسته به طور گسترده‌ای مورد استفاده قرار می‌گیرد (ژانگ و همکاران، ۲۰۱۵؛ کانگ و همکاران، ۲۰۱۵). با این حال، فن‌های خطی سنتی همیشه با دستگاه‌های پیچیده‌ای کار نمی‌کنند. فن‌های غیرخطی به واسطه توانایی در شبیه‌سازی دستگاه‌های پیچیده توجه بیشتری را به خود جلب کرده‌اند. شبکه عصبی BP دارای قابلیت غیرخطی قوی است که می‌تواند به توابع غیرخطی پیچیده دلخواه نزدیک شود. این توانایی را می‌توان برای ارتباط یک سری زمانی غیرخطی در یک فضای حالت تأخیری برای دستیابی به پیش‌بینی‌ها استفاده کرد. کاربرد شبکه عصبی BP نیاز به تعیین ساختار پیشرفته دارد. بهینه‌سازی ساختار شبکه یک بخش محبوب تحقیقاتی است. شبکه‌های عصبی BP باید یک‌لایه ورودی و یک‌لایه خروجی داشته باشند، که

به واسطه همین مسئله عملی تعیین می‌شوند. بنابراین تأکید و دشواری طراحی ساختار شبکه در طراحی ساختار لایه پنهان، به‌ویژه تعداد لایه‌های پنهان و تعداد نورون‌ها در هر لایه پنهان را در برمی‌گیرد. ساختار لایه‌های پنهان عمدتاً سرعت و قابلیت تعلیق شبکه‌های عصبی BP را تعیین می‌کنند. تعدادی از لایه‌های پنهان توسط بسیاری از محققان به لحاظ نظری مورد مطالعه قرار گرفته است. از لحاظ نظری ثابت شده است که یک شبکه عصبی BP سه لایه می‌تواند هر نقشه‌برداری غیرخطی پیچیده را شبیه‌سازی کند. اگر نورون‌های کافی در لایه پنهان وجود داشته باشند (ژانگ و همکاران، ۲۰۰۳؛ چائو و گو، ۲۰۰۳). بازار سهام یک سیستم غیرخطی بسیار ناپایدار است که نه تنها تحت تاثیر اقتصاد جهانی بلکه همچنین اقدامات انسانی و مقررات دولتی قرار دارد. بنابراین، داده‌های نمونه سهام باید تحت عملیات عادی بازار سهام برای بهبود قابلیت پیش بینی شبکه انتخاب شوند؛ در غیر این صورت، داده‌های ویژه قابلیت پیش بینی شبکه را کاهش می‌دهد. در آموزش شبکه، داده‌ها باید تمام انواع مدل‌های نمونه را شامل شوند. مدل‌های ورودی و خروجی نمونه‌ها در نگاره ۱ آورده شده است. داده‌های مربوط به قیمت سهام روزانه توسط n بیان می‌شود و m تعداد روزهای قیمت سهام را بیان می‌کند. در یک سری زمانی بنابراین، تعداد گره در لایه ورودی $n \times m$ ، تعداد نورون‌ها در لایه خروجی n است، و تعداد نمونه‌های تولید شده Q در شبکه عصبی است. برای یک شبکه عصبی سه بعدی BP، تعداد گره‌های موجود در لایه ورودی و نورون‌ها در لایه خروجی می‌تواند با مشکل واقعی تعیین شوند، اما طراحی تعداد نورون‌ها در لایه پنهان هنوز مورد پژوهش قرار نگرفته است. در اینجا، برای تعیین تعداد نورون‌ها در لایه پنهان، از فرمول‌های تجربی زیر استفاده می‌شود (میرچاندانی و گائو، ۱۹۸۹).

$$m = \sqrt{n+l} + \alpha, \quad (14)$$

$$m = \log_2 n, \quad (15)$$

$$m = \sqrt{n \times l}, \quad (16)$$

جایی که تعداد نورون‌ها در لایه پنهان توسط m بیان می‌شود؛ تعداد نورون‌ها در لایه خروجی توسط l بیان می‌شود؛ تعداد گره‌ها در لایه ورودی به صورت n بیان می‌شود. و یک ثابت بین 1 و 10 را بیان می‌کند. علاوه بر این، تعداد نورون‌ها در لایه پنهان با تعداد نمونه‌های آموزشی مرتبط است. تعداد نورون‌ها در لایه پنهان نیز می‌تواند توسط عبارت زیر تعیین شود.

$$m = \frac{1}{n+l+1} \left[\frac{Q}{(1.5 \sim 2)} - l \right]$$

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP... / وطن پرست، اسدی، محمدی و بابایی

مشتق تابع انتقال مورد نیاز در فرایند آموزش شبکه عصبی است. تابع انتقال اغلب مورد استفاده یک تابع زیگموئیدی یکپارچه است و بیان آن به شرح زیر است:

$$f(x) = \frac{1}{1+e^{-x}}$$

در این پژوهش، یک تابع هایپربولیک به عنوان تابع انتقال استفاده می شود زیرا سرعت همگرایی سریع تر از تابع زیگموئید یکپارچه تحت شرایط مشابه دارد. عبارت به شرح زیر است:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

نگاره ۱. مدل های ورودی و خروجی

نمونه Q		نمونه q		نمونه ۲		نمونه ۱	
بردار خروجی	بردار ورودی	بردار خروجی	بردار ورودی	بردار خروجی	بردار ورودی	بردار خروجی	بردار ورودی
$x_{1,1}$		$x_{2,1}$		$x_{q,1}$		$x_{Q,1}$	
$x_{1,2}$		$x_{2,2}$		$x_{q,2}$		$x_{Q,2}$	
\vdots		\vdots		\vdots		\vdots	
$x_{1,n}$		$x_{2,n}$		$x_{q,n}$		$x_{Q,n}$	
$x_{2,1}$		$x_{3,1}$		$x_{q+1,1}$		$x_{Q+1,1}$	
$x_{2,2}$		$x_{3,2}$		$x_{q+1,2}$		$x_{Q+1,2}$	
\vdots		\vdots		\vdots		\vdots	
$x_{2,n}$	$x_{m+1,1}$	$x_{3,n}$	$x_{m+2,1}$	$x_{q+1,n}$	$x_{q+m,1}$	$x_{Q+1,n}$	$x_{Q+m,1}$
\vdots	$x_{m+1,2}$	\vdots	$x_{m+2,2}$	$\dots \vdots$	$x_{q+m,2}$	$\dots \vdots$	$x_{Q+m,2}$
$x_{i,1}$	\vdots	$x_{i+1,1}$	\vdots	$x_{i+q-1,1}$	\vdots	$x_{i+Q-1,1}$	\vdots
$x_{i,2}$	y_{m+1n}	$x_{i+1,2}$	x_{m+2n}	$x_{i+q-1,2}$	$x_{q+m,n}$	$x_{i+Q-1,2}$	$x_{Q+m,n}$
\vdots		\vdots		\vdots		\vdots	
$x_{i,n}$		$x_{i+1,n}$		$x_{i+q-1,n}$		$x_{i+Q-1,n}$	
\vdots		\vdots		\vdots		\vdots	
$x_{m,1}$		$x_{m+1,1}$		$x_{q+m-1,1}$		$x_{Q+m-1,1}$	
$x_{m,2}$		$x_{m+1,2}$		$x_{q+m-1,2}$		$x_{Q+m-1,2}$	
\vdots		\vdots		\vdots		\vdots	
$x_{m,n}$		$x_{m+1,n}$		$x_{q+m-1,n}$		$x_{Q+m-1,n}$	

در این پژوهش، تابع انتقال لایه خروجی با $y = x$ جایگزین می شود. در مقایسه با عملکرد مبهم هیپربولیک، $y = x$ این اثر به عنوان عملکرد انتقال لایه خروجی از شبکه عصبی BP می تواند بر ناتوانی ها و به طور موثر بهبود پیش بینی دقیق غلبه کند.

فرضیه پژوهش

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP و برآورد نقطه بیش از حد توسط RDCI نسبت به روش های موجود نتایج بهتری را ارائه می دهد.

روش شناسی پژوهش

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP

ساعت بازار بورس سهام از شنبه تا پنجشنبه است، بنابراین در این پژوهش، هر نمونه حاوی یک بردار با داده های پنج روز از اطلاعات قیمت سهام می باشد. و طور کامل از قوانین قیمت سهام، متغیرهای ورودی باید شامل قیمت روز باز قیمت X_{i1} ، بالاترین قیمت X_{i2} ، قیمت پایین X_{i3} ، قیمت بسته شدن X_{i4} ، و حجم معاملات X_{i5} ، (من تعداد روزهای نمونه را بیان می کنم، $i = \{1, 2, 3, 4, 5\}$) می باشد. بنابراین، تعداد گره ها در لایه ورودی ۲۵ است. داده های قیمت سهام در روز ششم از داده های روز پنج روز گذشته محاسبه می شود. متغیرهای خروجی عبارتند از قیمت افت قیمت y_1 ، بالاترین قیمت y_2 ، پایین ترین قیمت y_3 ، قیمت بسته شدن y_4 و حجم معاملات y_5 در روز ششم و تعداد نوروں ها در لایه خروجی ۵ است. در این پژوهش، ۳۱۵ روز قیمت سهام برای ایجاد ۳۱۰ نمونه آموزشی انتخاب می شود و مجموعه آزمون شامل قیمت سهام از روز ۳۱۶ تا روز ۳۲۰ می باشد.

فرآیند آموزش و تست الگوریتم

شبکه عصبی BP در مرحله پخش سیگنال پیشین و مرحله پخش پیام خطا در بالا ذکر شده است. مقادیر پارامتر الگوریتم $\Theta = 1: 0001$ و $\mu = 0.36$ است. نمونه های آزمایشی برای تست قابلیت استخراج عصبی شبکه های عصبی آموزش دیده توسط الگوریتم LM-BP مورد استفاده قرار می گیرند. ان مراحل خاص به شرح زیر است: ۱- ایجاد شبکه عصبی BP با وزن و آستانه که توسط الگوریتم LM-BP به روز می شود؛ ۲- فرم یک نمونه را با داده های قیمت سهام از روزهای گذشته (از روزهای ۳۱۱ تا ۳۱۵) در تمرین تعیین شده توسط مدل های ورودی و خروجی در نگاره ۲ تشکیل می دهد. نمونه ی نرمال شده برای ورود به شبکه عصبی برای پیش بینی قیمت سهام روز ۳۱۶ است. ۳- یک نمونه دیگر با اطلاعات قیمت سهام از چهار روز قبل (از ۳۱۲ تا ۳۱۵ روز) در فرم

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP /... وطن پرست، اسدی، محمدی و بابایی

مجموعه آموزش و داده های پیش بینی شده از روز ۳۱۶ توسط مدل های ورودی و خروجی در نگاره ۲ آمده است.

نگاره ۲ مدل های ورودی و خروجی پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP

نمونه Q		نمونه q		نمونه ۲		نمونه ۱	
بردار خروجی	بردار ورودی	بردار خروجی	بردار ورودی	بردار خروجی	بردار ورودی	بردار خروجی	بردار ورودی
$x_{1,1}$		$x_{2,1}$		$x_{q,1}$		$x_{311,1}$	
$x_{1,2}$		$x_{2,2}$		$x_{q,2}$		$x_{311,2}$	
$x_{1,3}$		$x_{2,3}$		$x_{q,3}$		$x_{311,3}$	
$x_{1,4}$		$x_{2,4}$		$x_{q,4}$		$x_{311,4}$	
$x_{1,5}$		$x_{2,5}$		$x_{q,5}$		$x_{311,5}$	
$x_{2,1}$		$x_{3,1}$		$x_{q+1,1}$		$x_{312,1}$	
$x_{2,2}$		$x_{3,2}$		$x_{q+1,2}$		$x_{312,2}$	
$x_{2,3}$		$x_{3,3}$		$x_{q+1,3}$		$x_{312,3}$	
$x_{2,4}$		$x_{3,4}$		$x_{q+1,4}$		$x_{312,4}$	
$x_{2,5}$		$x_{3,5}$		$x_{q+1,5}$		$x_{312,5}$	
$x_{3,1}$	$y_{6,1}$	$x_{4,1}$	$y_{7,1}$	$x_{q+2,1}$	$y_{q+5,1}$	$x_{313,1}$	$y_{315,1}$
$x_{3,2}$	$y_{6,2}$	$x_{4,2}$	$y_{7,2}$	$x_{q+2,2}$	$y_{q+5,2}$	$x_{313,2}$	$y_{315,2}$
$x_{3,3}$	$y_{6,3}$	$x_{4,3}$	$y_{7,3}$	$x_{q+2,3}$	$y_{q+5,3}$	$x_{313,3}$	$y_{315,3}$
$x_{3,4}$	$y_{6,4}$	$x_{4,4}$	$y_{7,4}$	$x_{q+2,4}$	$y_{q+5,4}$	$x_{313,4}$	$y_{315,4}$
$x_{3,5}$	$y_{6,5}$	$x_{4,5}$	$y_{7,5}$	$x_{q+2,5}$	$y_{q+5,5}$	$x_{313,5}$	$y_{315,5}$
$x_{4,1}$		$x_{5,1}$		$x_{q+3,1}$		$x_{314,1}$	
$x_{4,2}$		$x_{5,2}$		$x_{q+3,2}$		$x_{314,2}$	
$x_{4,3}$		$x_{5,3}$		$x_{q+3,3}$		$x_{314,3}$	
$x_{4,4}$		$x_{5,4}$		$x_{q+3,4}$		$x_{314,4}$	
$x_{4,5}$		$x_{5,5}$		$x_{q+3,5}$		$x_{314,5}$	
$x_{5,1}$		$x_{6,1}$		$x_{q+4,1}$		$x_{314,1}$	
$x_{5,2}$		$x_{6,2}$		$x_{q+4,2}$		$x_{314,2}$	
$x_{5,3}$		$x_{6,3}$		$x_{q+4,3}$		$x_{314,3}$	
$x_{5,4}$		$x_{6,4}$		$x_{q+4,4}$		$x_{314,4}$	
$x_{5,5}$		$x_{6,5}$		$x_{q+4,5}$		$x_{314,5}$	

به طور مشابه، نمونه عادی برای ورود به شبکه عصبی برای پیش بینی قیمت سهام در ۳۱۷ روز می باشد. ۴-مراحل ۱ و ۲ را تکرار کنید. این روند تا زمانی که تعداد روزها در پیش بینی اطلاعات قیمت سهام برابر با Q_t تعداد روزها در مجموعه آزمون) نباشد، کامل نخواهد شد. ۵- فرمول محاسبات خطای مربوط به میانگین (MRE1) به صورت زیر نشان داده شده است. خطای نسبی خطای پیش بینی (MRE2) را می توان با فرمول زیر با مقدار مشاهده شده در مجموعه آزمون محاسبه کرد و توانایی استخراج شبکه عصبی با استفاده از MRE2 اندازه گیری می شود.

$$MRE1 = \frac{1}{S^2 \times Q} \left(\sum_{j=1}^{S^2} \sum_{q=1}^Q \left| \frac{d'_t - a^{2t}}{d'_t} \right| \right);$$

$$MRE2 = \frac{1}{S^2 \times Q_t} \left(\sum_{j=1}^{S^2} \sum_{q=1}^Q \left| \frac{d'_t - a^{2t}}{d'_t} \right| \right);$$

که در آن d'_t ارزش مشاهده شده قیمت سهام در مجموعه تست است، a^{2t} خروجی ضد عادی شبکه عصبی در فرآیند تست است، d' ارزش مشاهده شده قیمت سهام در مجموعه آموزشی است و a^2 خروجی شبکه عصبی در روند آموزش را نرمال نشان می دهد.

دریافت پیش بینی و خطاهای احتمالی


فرآیند محاسبه ۳،۲ تا $\varepsilon < MRE1$ را تکرار کنید و روند آموزش کامل شده است. ε توسط روش آزمون به دست آمده است. مقدار کوچکی از ε ممکن است به طور قابل توجهی افزایش زمان آموزش شبکه عصبی را افزایش دهد و شبکه عصبی ممکن است نیاز دقیق ε را به دست نیورد. مقدار ε که بیش از حد بزرگ است ممکن است به مقادیر بزرگتر MRE1 و MRE2 منجر شود، باعث پیش بینی شبکه های ضعیف عصبی و خطای پیش بینی شده می شود که به حالت بحرانی MRE2 نمی رسد، که از کاهش به افزایش می یابد، که به طور قابل توجهی بر دقت فرآیند تجزیه و تحلیل بعدی می افزاید. بنابراین، $\varepsilon = 1\%$ در این پژوهش این گونه است. منحنی MRE2-MRE1 را می توان با فرآیند فوق بدست آورد.

تقسیم تکرار و شمارش در فواصل زمانی (RDCI)

با توجه به ساختار مشابه شبکه های عصبی و نمونه های آموزشی، هر چند وزن های اولیه و تعصب های تصادفی (متفاوت)، با افزایش زمان آموزش و تعداد تکرارها، چندین فرآیند آموزش دارای برخی از شباهت ها هستند. به طور کلی، دقت تناسب سازی از شبکه به تدریج افزایش می یابد و توسط MRE1 به تدریج کاهش می یابد: در ابتدا، مقدار MRE1 بزرگ است و به سرعت در حال

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP.../ وطن پرست، اسدی، محمدی و بابایی


کاهش است. سپس، با کاهش MRE1، سرعت دقیق تر شدن، به آرامی کاهش می یابد. در نهایت، با مقادیر بسیار کم MRE1، تغییر در سرعت تقریباً متوقف می شود. در این فرایند، دقت پیش بینی (MRE2) به دلیل کاهش MRE1 (پس از بیش از نقطه بیش از حد)، MRE1 قبل از افزایش افزایش می یابد. با این حال، برای وزن های مختلف و تعصب های مختلف، تمام فرایندهای آموزشی از قانون تنوع دنبال می شوند. ما نتیجه گرفتیم که دقت تناسب سازی مربوط به بهترین دقت پیش بینی شبکه عصبی BP منطقی بر اساس چند آزمایش مستقل تکرار شده است. هیچ نظریه قابل اعتمادی برای تعیین نقطه بیش از حد وجود ندارد (پانگ و بردینه، ۲۰۱۵؛ دنگ و همکاران، ۲۰۱۵)، بنابراین در این پژوهش، تقسیم تکرار و شمارش در فواصل زمانی (RDCI) برای تعیین نقطه بحرانی بیش از حد تعیین کننده شبکه عصبی BP پیشنهاد شده است. مفهوم اساسی در پشت این روش به شرح زیر است: برای هر منحنی MRE2-MRE1، دقت در دسترس پیش بینی MRE2₁ است و دامنه MRE2₁ که مینویسد MRE2 MRE $MRE2_1 \in [MRE2_L, MRE2_H]$ ؛ دقت در دسترس بودن پیش بینی MRE2 و محدوده MRE1 است که MRE1₂ IS MRE2₂ $\in [MRE2_L, MRE2_H]$ را تحمل می کند و سپس برای همه فرایندهای آموزشی (مشخص شده آموزش نمونه ها و ساختار مشابه شبکه)، دقت (MRE1₁) تناسب سازی شبکه را می توان با روش های آماری با استفاده از n بدست آورد



شکل ۱ منحنی MRE2-MRE1

فاصله زمانی $MRE2_1^1, MRE2_1^2, \dots, MRE2_1^m, \dots, MRE2_1^n$ زمانی که دقت مشخصی از پیش بینی MRE2₁ است. به هر حال، ما می توانیم نتایج دقیق MRE12 را که مربوط به دقت پیش بینی MRE2₂ می باشد، دریافت کنیم. در نهایت، ما می توانیم دقت *MRE1 از نقطه بیش از حد بر اساس تمام مقادیر MRE1 به دست آوریم: MRE2 و... به عنوان مثال، با توجه به شکل ۱، یک توصیف مختصر از مراحل خاص این روش به شرح زیر است: ۱- چندین بار تکرار مراحل ۲.۳

و ۳،۳ منحنی های مختلف MRE2-MRE1 برای وزن های اولیه و آستانه های شبکه عصبی به طور تصادفی تولید می شود. ۲- به عنوان نمونه یک منحنی MRE2-MRE1 را بیابید. هنگامی که دقت پیش بینی پیش بینی $MRE2 \leq 1$ است، مقدار MRE1 در شکل نشان داده شده است، جایی که نقاط سیاه بیانگر ارزش MRE2 ملاقات الزامات دقت و نقاط قرمز مورد نیاز نیست. که طبق شکل، نوسانات نامنظم زمانی رخ می دهد که $1.3\% < MRE1 < 1\%$. در این لحظه، ساختار شبکه ناپایدار است؛ چندین نقطه مطابق الزامات دقت، اما اگر MRE1 در محدوده خود افزایش یا کاهش یابد، MRE2 ممکن است به شدت افزایش یابد. بنابراین، MRE1 در این فاصله قابل اعتماد نیست و نقطه بیش از حد باید به سمت راست از $MRE1 = 1.3\%$ باشد. به طور مشابه، عملیات فوق برای تمام منحنی های MRE2-MRE1 انجام می شود و نمودارهای هماهنگی یک بعدی به دست می آید. در نهایت، با توجه به دقت مورد انتظار $MRE2 \leq 1$ ، نقطه احتمالی ممکن است با شمارش تمام مختصات یک بعدی به طور مستقیم برآورد شود. ۳- به همین ترتیب، بعد از مرحله ۲، تحت شرایط دقیق بودن انتظار می رود $MRE2 < 1.5\%$ ، $MRE2 < 2\%$ ، $MRE2 < 2.5\%$ ، مقادیر نقطه احتمالی ممکن است به طور مستقیم برآورد شود. ۴- در نهایت، یک نقطه قابل اطمینان بیش از نقطه بحرانی شبکه عصبی BP را می توان با ترکیب تمام مقادیر ممکن از نقطه بیش از حد در مراحل ۲ و ۳ بدست آورد.




شکل ۲ منحنی ۱۰۰ آزمایش مستقل

بنابراین، سهامی باید انتخاب شود که در تغییرات با ثبات و کمتر تحت تاثیر سیاست، اقتصاد و فرهنگ قرار داشته باشد. مقادیری که از عوامل عدم اطمینان و قابل اعتماد در قوانین تغییر می کنند، نباید انتخاب شوند. بنابراین، در این پژوهش، سه سهام که همه آنها در بورس اوراق بهادار تهران فهرست شده اند، برای پیش بینی قیمت سهام انتخاب شده اند.

یافته های پژوهش

پیش بینی قیمت سهام

۱- فرآیند آموزش و انتخاب نقطه ی نقاط تعطیلی مجموعه ی آموزشی شامل ۳۱۵ روز از قیمت سهام، که ۳۱۰ نمونه ی آموزشی را تولید می کند. مجموعه آزمون شامل ۵ روز قیمت سهام می شود. تکرار مراحل ۱.۳ تا ۴.۳ بار. سپس ۱۰۰ منحنی MRE2-MRE1 مختلف را می توان برای مقادیر اولیه و آستانه های شبکه عصبی به طور تصادفی تولید کرد. تجزیه و تحلیل زیر توسط RDCI انجام می شود. نوسانات نامنظم، زمانی شروع می شوند که $1.3\% < MRE1 < 1\%$ باشد. در این لحظه، ساختار شبکه ناپایدار است، MRE1 در این فاصله قابل اعتماد نیست و نقطه بیش از حد باید به سمت راست $MRE1 = 1.3\%$ باشد. در شرایط دقیق مورد انتظار $MRE2 < 2.5\%$ ، نتیجه ۱۰۰ آزمایش مستقل مشخص است. محدوده MRE1 زمانی که $MRE2 < 2.5\%$ می تواند برای هر خط بدست آید، و نقطه بیش از حد نقطه، که بیشتر در ۱۰۰ آزمایش مستقل تکرار شده تکرار می شود. مقدار MRE1 از نقطه بیش از حد را می توان به دست آورد. بنابراین، در شرایط دقیق مورد انتظار، $MRE1 = 0.01325$ ، $MRE2 < 2.5\%$ در نقطه بیش از حد می باشد. به طور مشابه، در شرایط دقیق مورد انتظار $MRE2 \leq 2.0\%$ ، نتایج ۱۰۰ آزمایش مستقل مشخص است. با توجه به دقت مورد انتظار $MRE2 < 1.5\%$ ، نتایج ۱۰۰ آزمایش مستقل مشخص است. در شرایط دقیق مورد انتظار $MRE2 < 1\%$ ، نتایج ۱۰۰ آزمایش مستقل در نیز مشخص است. از طریق تجزیه و تحلیل فوق، سطح اطمینان $MRE1 = 1.325\%$ از نقطه بیش از حد در نگاره ۳ آمده است. نقطه بیش از حد انتخاب شده که نشان از قابلیت اعتماد و تطابق با الزامات دقیق پیش بینی شده دارد. ۲- ماتریس وزن و آستانه، بر اساس نقطه بیش از حد تعیین شده در ۱، وزن و آستانه شبکه عصبی می تواند تعیین شود و به صورت زیر نمایش داده می شود:



شکل ۳ مقدار MRE1 زمانی که $MRE2 \leq 2.5\%$ است

نگاره ۳. دقت پیش بینی و سطح اطمینان

سطح اطمینان (%)	دقت پیش بینی (MRE2) (%)
۹۰	۲,۶
۷۷	۲,۱
۵۷	۱,۷
۲۴	۱,۱

۲- مجموعه های فازی را حذف کنید، با توجه به ده فاصله زمانی از نگاره ۵، مجموعه های فازی به صورت $A = \{A_1, A_2, \dots, A_i, \dots, A_9, A_{10}\}$ تعریف می شوند، در حالیکه A_i متغیر زمانی مجموعه های فازی تولید شده بواسطه قیمت بسته قیمت سهام است.

نگاره ۴ پیش بینی و تحلیل قیمت سهام

روز آموزش	قیمت آزاد یا باز		بالاترین قیمت		کمترین قیمت		قیمت بسته	
	مشاهده شده مقدار	پیش بینی مقدار	مشاهده شده مقدار	پیش بینی مقدار	مشاهده شده مقدار	پیش بینی مقدار	مشاهده شده مقدار	پیش بینی مقدار
	۲۲,۶۴	۲۲,۸۴	۲۳,۰۵	۲۳,۲۴	۲۲,۶۰	۲۲,۶۱	۲۲,۶۹	۲۳,۰۶
	۲۲,۷۴	۲۲,۸۹	۲۳,۰۴	۲۳,۲۸	۲۲,۵۱	۲۲,۶۵	۲۲,۵۰	۲۳,۰۸
	۲۲,۵۱	۲۲,۸۶	۲۲,۶۵	۲۳,۳۱	۲۲,۹۱	۲۲,۶۸	۲۲,۴۸	۲۳,۰۹
	۲۲,۳۹	۲۳,۰۱	۲۲,۶۴	۲۳,۴۸	۲۲,۳۱	۲۲,۸۷	۲۲,۶۹	۲۳,۳۷
	۲۲,۵۴	۲۱,۱۸	۲۲,۶۱	۲۳,۶۱	۲۲,۲۷	۲۲,۸۴	۲۲,۴۵	۲۳,۴۱
میانگین خطای نسبی (%)	۱,۷۴		۲,۸۱		۱,۵۷		۲,۶۹	

نگاره ۵. ۱۰ فواصل زمانی برای قیمت بسته شدن قیمت سهام

فاصله زمانی	رویداد
$u_1 = [17.91, 20.02]$	۲۱
$u_2 = [22.04, 23.07]$	۳۳
$u_3 = [23.09, 24.13]$	۴۱
$u_4 = [24.15, 22.18]$	۲۷
$u_5 = [22.17, 23.24]$	۲۰
$u_6 = [24.22, 27.29]$	۴۲
$u_7 = [24.37, 29.33]$	۳۶
$u_8 = [25.32, 31.44]$	۴۱
$u_9 = [27.48, 32.55]$	۳۵
$u_{10} = [30.56, 31.65]$	۱۶

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP /... وطن پرست، اسدی، محمدی و بابایی

نگاره ۶ سری زمانی ارزش زبان شناختی برای قیمت پایانی قیمت سهام

ارزش زمانی	قیمت بسته
A_3	۲۳,۵۴
A_3	۲۳,۳۲
A_2	۲۳,۰۷
:	:
A_3	۲۳,۶۲
A_3	۲۴,۱۹
A_3	۲۳,۱۱

۳- روابط منطقی فازی را تعیین کنید. از نگاره ۶، روابط منطقی فازی قیمت بسته قیمت سهام به شرح زیر است:

$$A_3 \rightarrow A_3, A_3 \rightarrow A_2, \dots, A_3 \rightarrow A_3, A_3 \rightarrow A_3$$

۴- تعیین رابطه گروه منطقی فازی با توجه به روابط منطقی فازی از ۳،

نگاره ۷ پیش بینی قیمت بسته قیمت با استفاده از سری زمانی فازی

میزان پیش بینی	میران مشاهده شده
۲۲,۹۳	۲۲,۶۲
۲۲,۷۸	۲۲,۵۳
۲۲,۸۴	۲۲,۴۹
۲۲,۸۶	۲۲,۵۸
۲۲,۸۸	۲۲,۴۶
	میانگین خطای نسبی
	٪۱۳,۴۵۱

فرض کنید $P(T)$ قیمت بسته در زمان t باشد، $P(T-1)$ قیمت بسته در زمان $t-1$ است. اگر $P(T-1) = A_3$ ، پیش بینی های احتمالی برای A_2 $P(T)$ باشد؛ A_3 و A_4 بعد از محاسبات، وزن ماتریس نتایج پیش بینی می تواند با استفاده از معادله پیش بینی سازگار (معادله ۲۳) بدست آید. نتایج در نگاره ۷ آمده اند.

$$P(T) = P(T-1) + \alpha (F(T) - P(T-1))$$

واضح است که: روش پیشنهادی دقیق تر از سری زمانی فازی است. بر اساس عملکرد عالی، دو آزمایش اضافی با استفاده از سهام مختلف ضروری است.

پیش بینی قیمت سهام

مجموعه آموزش شامل ۳۱۵ روز قیمت سهام و تولید ۳۱۰ نمونه آموزشی است. مجموعه آزمون شامل ۵ روز قیمت سهام است. مراحل ۱.۳ تا ۴.۳، ۱۰۰ بار تکرار کنید ۴ سپس، ۱۰۰ منحنی متفاوت MRE2-MRE1 (شکل ۱۱) برای وزن های اولیه و آستانه های شبکه عصبی به طور تصادفی بدست می آید. از طریق تجزیه و تحلیل با استفاده از روش RDCI، سطح اطمینان % MRE1 = 1.322 از نقطه بحرانی بیش برداش در نگاره ۸ نشان داده شده است. که گویای آن است که: نقطه بحرانی بیش برداش که در این پژوهش انتخاب شده است بیشتر قابل اعتماد است و با الزامات پیش بینی دقیق مطابقت دارد. بر اساس نقطه نظرهای به دست آمده در ۱، وزن و آستانه شبکه عصبی می تواند انجام شود و به شرح زیر نشان داده شده است:

$$\begin{aligned} w^2 &= [-0.03160.07160.02732.6298 - 0.0061 - 0.0794 - 0.0379; \\ &\quad -0.04460.12470.13642.83120.0304 - 0.1925 - 0.0886; \\ &\quad -0.0301 - 0.04900.04262.9174 - 0.00870.0454 - 0.0478; \\ &\quad -0.03900.02470.08322.60760.0060 - 0.0782 - 0.0497; \\ &\quad -0.03551.67850.8961 - 0.59140.1276 - 2.1537 - 0.3881; \\ b^1 &= [-0.4768; 0.8892; 0.5552; -0.1055; 2.8718; 0.2869; 2.3851]. \\ b^2 &= [0.4370; 0.3561; 0.3567; 0.2520; -0.5799]. \end{aligned}$$

تجزیه و تحلیل پیش بینی و دقت قیمت سهام نشان داده شده است. مجموعه آموزش شامل ۳۱۵ روز تمرین از قیمت سهام و تولید ۳۱۰ نمونه آموزشی است. مجموعه آزمون شامل ۵ روز تمرین از قیمت سهام است. مراحل ۱، ۳-۴، ۱۰۰ بار تکرار کنید. سپس، ۱۰۰ منحنی MRE2-MRE1 مختلف برای وزن های اولیه و آستانه های شبکه عصبی به طور تصادفی بدست می آید. از طریق تجزیه و تحلیل با استفاده از روش RDCI، سطح اطمینان از نقطه بحرانی بیش از حد مشخص می گردد.

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP.../ وطن پرست، اسدی، محمدی و بابایی

$$w^2 = [2.74141.67290.38973.12341.7231 - 0.0514.3.3220 - 0.57882.13282.52623.29073.10502.8101 - 0.04891.21741.9443 - 1.14920.0927 - 1.19640.62241.1888 - 0.28680.9246 - 2.5244 - 0.5137; 1.27290.86401.0701 - 0.14932.35230.99961.22760.72293.0708 - 1.50301.37220.83722.51290.37730.39660.8454 - 1.26261.80830.23621.4427 - 0.5628 - 4.11402.39673.62191.6351; -1.54784.78383.82520.92671.3426 - 1.52922.3751 - 0.34937.1502 - 0.45611.73512.13054.8603 - 0.7408 - 0.02710.6680 - 4.27054.89491.22740.6945 - 0.5035 - 1.40320.62661.44793.2701; 0.0050 - 0.04220.01130.02370.01100.0032 - 0.03140.01700.05240.0184 - 0.03540.01360.01150.01900.0038 - 0.05180.0.2300.0731 - 0.0612 - 0.0003 - 0.01210.02900.03180.2990 - 0.0082; 2.3526 - 1.2741 - 1.0342 - 2.3440 - 0.03733.9629 - 3.23281.01160.53341.5823 - 1.04161.77950.43431.89580.4759 - 0.63471.68920.39660.2454 - 0.0169 - 0.93430.1910 - 0.0881 - 2.0421.5539; 0.41372.10951.6230 - 0.00902.04971.34651.8739 - 0.04984.9238 - 1.90041.81961.42623.0168 - 0.1399 - 0.02390.6960 - 2.26072.9455 - 0.02231.4690 - 0.5572 - 4.34192.73433.00472.0251; 0.34521.67473.72430.06632.10400.0789 - 1.24321.52024.54523.8230 - 2.34270.89466.00910.96540.03013.19332.61482.37810.99000.0730 - 0.8746 - 0.4617 - 3.80952.88911.0032].$$

نگاره ۸. دقت پیش بینی سطح اطمینان

میزان اطمینان (%)	دقت پیش بینی (MRE2) (%)
۸۲	۳
۶۲	۲
۵۱	۱,۵
۲۸	۲
۸	۱

نقطه بحرانی بیش از حد انتخاب شده در این پژوهش قابل اعتمادتر است و نیازهای پیش بینی دقیق تری را برآورده می کند. بر اساس نقطه بیش از حد تعیین شده در ۱، وزن و آستانه شبکه عصبی می تواند انجام شود و به صورت زیر نمایش داده می شود:

نگاره ۹ پیش بینی و تحلیل دقت قیمت سهام

	قیمت آزاد یا باز		بالاترین قیمت		کمترین قیمت		قیمت بسته	
	مشاهده شده مقدار	پیش بینی مقدار	مشاهده شده مقدار	پیش بینی مقدار	مشاهده شده مقدار	پیش بینی مقدار	مشاهده شده مقدار	پیش بینی مقدار
	۱۵,۴	۱۵,۴۳	۱۵,۶۱	۱۵,۸۴	۱۵,۳۵	۱۵,۱۹	۱۵,۴۹	۱۵,۵۱
	۱۵,۳۳	۱۵,۴۲	۱۵,۵۷	۱۵,۹۲	۱۵,۲۰	۱۵,۱۷	۱۵,۳۲	۱۵,۵۴
	۱۵,۴۲	۱۵,۵۸	۱۵,۵۰	۱۵,۸۴	۱۵,۲۴	۱۵,۲۱	۱۵,۴۲	۱۵,۵۹
	۱۶,۴۷	۱۶,۵۹	۱۶,۴۸	۱۶,۸	۱۵,۳۶	۱۵,۲۷	۱۵,۴۰	۱۵,۶۳
	۱۵,۴۹	۱۵,۶۱	۱۵,۶۰	۱۶,۱۰	۱۵,۴۶	۱۵,۲۸	۱۵,۶۲	۱۵,۷۱
میانگین خطای نسبی (%)	۰,۸۱		۲,۸۸		۰,۷۵		۱,۱۱	

w^1
 = [1.72303.10230.66440.48501.31241.67293.69121.28270.41785.2183
 - 0.51780.29082.08412.35201.96983.38781.43715.17210.73234.97343.52722.07453.76220.87391.5771; 3.1291
 - 3.07873.66241.25944.59552.60772.23026.31616.85992.85152.70980.1757
 - 0.05830.12485.00202.86611.63752.41891.50157.26893.13223.82304.87572.58872.2018; -2.19601.12181.1490
 - 1.4646 - 0.43771.37302.48501.97810.8464 - 1.7983
 - 1.52650.44394.43543.42720.14701.0808 - 0.59962.7443
 - 0.70891.37240.54950.23531.3127 - 0.33091.7164; 0.1985 - 2.1582 - 0.05123.8071
 - 0.7886 - 0.8483 - 3.06334.7947 - 0.8202 - 161854.24250.9884 - 1.56384.5517
 - 0.44084.2137 - 2.27272.43202.84111.91720.6927
 - 2.52470.26800.74811.8381; -0.3074 - 2.04122.97490.04600.8120 - 1.86260.6442
 - 0.1295 - 0.9879 - 0.18860.75660.3796 - 0.32781.27970.0553 - 0.5434 - 0.6799
 - 1.68931.2713 - 0.4188 - 0.43571.50460.81571.99512.0360; 1.44841.94862.5800
 - 2.43024.03284.5739 - 0.72617.21048.41622.6700 - 0.59411.41010.3590
 - 1.61604.50514.69461.82970.16702.67456.54372.58050.96437.75531.76832.6485; 0.0343
 - 0.1231 - 0.05250.13080.00240.03060.0305 - 0.12350.0868 - 0.00760.0446
 - 0.07280.01320.00790.00160.06950.1184 - 0.1514 - 0.0233 - 0.01460.0412
 - 0.06630.03130.4772 - 0.0148].

نگاره ۱۰ دقت پیش بینی و سطح اطمینان

سطح اطمینان	دقت پیش بینی (MRE2) (%)
۷۷	۲
۷۹	۱,۵
۴۱	۱
۴	۲,۵

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP.../ وطن پرست، اسدی، محمدی و بابایی

$$w^2 = [0.02100.0417 - 0.15990.19240.0350 - 0.05522.0832; 0.00070.0419 - 0.43590.32670.0214 - 0.05672.0043; -0.00052.1579 - 0.17500.14920.0179 - 0.15742.0782; 0.02430.2384 - 0.18330.19140.0289 - 0.21642.0609; -0.0953 - 2.2923 - 1.31301.35300.19682.4419 - 0.6887].$$

$$b^1 = [0.7735; -0.2547; 0.5062; 0.5109; -0.3469; 0.0645; -0.0340$$

$$b^2 = [0.0350; -0.0017; -0.0006; 0.0174; -0.3105]$$

تجزیه و تحلیل پیش بینی و دقت قیمت سهام در نگاره ۱۱ نشان داده شده است.

نگاره ۱۱ پیش بینی و تحلیل دقت قیمت سهام

	قیمت بسته		کمترین قیمت		بالاترین قیمت		قیمت آزاد یا باز	
	پیش بینی	مشاهده شده	پیش بینی	مشاهده شده	پیش بینی	مشاهده شده	پیش بینی	مشاهده شده
	مقدار	مقدار	مقدار	مقدار	مقدار	مقدار	مقدار	مقدار
	۹۲,۳۶	۹۲,۲۸	۹۱,۳۰	۹۱,۸۱	۹۳,۴۱	۹۲,۸۵	۹۳,۳۴	۹۲,۸۵
	۹۲,۶۷	۹۲,۹۱	۹۰,۶۰	۹۲,۰۹	۹۲,۷۱	۹۳,۶۷	۹۲,۶۶	۹۲,۵۷
	۹۲,۸۹	۹۲,۶۳	۹۰,۸۳	۹۲,۴۱	۹۲,۹۳	۹۳,۷۵	۹۲,۸۷	۹۳,۲۲
	۹۲,۲۷	۹۲,۳۰	۹۰,۲۰	۹۳,۳۱	۹۳,۳۳	۹۵,۰۸	۹۳,۲۴	۹۳,۶۱
	۹۲,۷۸	۹۲,۶۶	۹۰,۷۳	۹۲,۳۷	۹۳,۸۴	۹۴,۴۲	۹۳,۷۵	۹۳,۵۶
درصد میانگین خطای نسبی		۱,۳۳		۱,۴۲		۱,۲۴		۰,۴۱

تکنیک هایی برای آزمون صحت مدل محاسباتی آن وجود دارد که به پس آزمون معروفند. در این بخش، دو روش آزمون کوپیک و آزمون پیش بینی فاصله ای کریستوفرسون جهت آزمون قدرت مدل پیش بینی استفاده می شود. در نگاره ۱۲ در سطح معناداری، آزمون کوپیک انجام شده و نتایج به دست آمده در خصوص فرض صفر یعنی صحت مدل، در جدول قابل مشاهده است. مدل از دیدگاه آزمون کوپیک از قدرت پیش بینی مناسبی برخوردار است. یکی دیگر از آزمون های سنجش قدرت مدل آزمون شرطی پیش بینی فاصله کریستوفرسون است که از همان چارچوب آزمون احتمال لگاریتمی کوپیک برخوردار است، اما آماره مجزایی را برای آزمون استقلال استثناها

در نظر می‌گیرد. نتایج آزمون کریستوفرسون به شرح جداول زیر است و مشاهده می‌شود که نتایج به دست آمده در این آزمون نیز دقیقاً همانند نتایج آزمون کوپیک می‌باشد.

نگاره ۱۲ نتایج آزمون کوپیک و کریستوفرسون

نتایج آزمون کوپیک			
نتیجه	مقدار بحرانی کای دو	آماره آزمون LR	سطح اطمینان
پذیرش مدل	۲,۷۱	۲,۴۶	٪۹۰
نتایج آزمون کریستوفرسون			
نتیجه	مقدار بحرانی کای دو	آماره آزمون LR	سطح اطمینان
پذیرش مدل	۴,۶	۴,۲	٪۹۰

بحث و نتیجه گیری

پیش بینی قیمت سهام دائماً در حال افزایش توجه است. در سال های اخیر، بسیاری از روش ها در این زمینه، مانند روش های باکس جینکینز، سری زمانی فازی، شبکه های عصبی BP و سایر موارد استفاده شده است. در این پژوهش، برای تعیین روش پیش بینی قیمت سهام، یک شبکه عصبی BP بر اساس یک سری زمانی با توجه به قیمت باز روز، بالاترین قیمت، پایین ترین قیمت، قیمت بسته و حجم معاملات، بکار گرفته شده است شبکه بر اساس یک سری زمانی می تواند روند قیمت سهام را در طی یک دوره زمانی بیشتر جامع تر نشان دهد و پایه ای برای پیش بینی های بعدی ایجاد کند. در این پژوهش الگوریتم LM-BP برای غلبه بر این معایب پیشنهاد شده است. در همین حال، مدل های ورودی و خروجی خاص قیمت پیش بینی قیمت سهام که متفاوت از پیش بینی های سری زمانی هستند، در این پژوهش ارائه شده است. عملکرد پیش بینی شده شبکه عصبی ضعیف است زیرا عملکرد انتقال لایه خروجی یک تابع مماسی هیپربولیک است. برای حل این مشکل، تابع انتقال لایه خروجی با یک تابع خط جایگزین شده و نمودار ساختار شبکه پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP در این پژوهش ارائه شده است. در حال حاضر هیچ دیدگاه مطمئن تری نسبت به تعیین نقطه بحرانی بیش از حد وجود ندارد. در این پژوهش، تقسیم، تکرار و شمارش در فواصل زمانی (RDCI) برای پیش بینی شکاف تحقیق پیشنهاد شده است. در این روش، منحنی MRE2-MRE1 کشیده می شود و دقت تناسب سازی مربوط به بهترین دقت پیش بینی شبکه عصبی BP بر اساس چندین تست مستمر مستقل برآورد شده است. در این پژوهش، سه سهام از

پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP... / وطن پرست، اسدی، محمدی و بابایی

بورس تهران برای پیش بینی قیمت سهام انتخاب شده اند. ماتریسهای وزن و آستانه شبکه عصبی این سه سهام داده شده است. قیمت های باز، بالاترین قیمت، پایین ترین قیمت ها و قیمت های بسته این سه سهام در روزهای آینده در مطالعات موردی پیش بینی شده است به علت عدم استفاده از روش باکس جینکینز در پیش بینی قیمت سهام، تست ها تنها بین روش پیشنهادی در این پژوهش و سری زمانی فازی مقایسه می شوند. نتایج تجربی نشان می دهد که روش پیشنهادی در این پژوهش می تواند همزمان چندین قیمت سهام را پیش بینی کند. علاوه بر این، نتایج پیش بینی دقیق است. نتایج تجربی و نیز نشان می دهد که پیش بینی قیمت سهام بر اساس شبکه عصبی LM-BP و برآورد نقطه بیش از حد توسط RDCI در این پژوهش نتایج بهتر از روش های موجود ارائه داده است. در این پژوهش، RDCI ارائه شده است تا مسائل مربوط به نقطه بیش از حد (بیش برداش) را حل کند.

محدودیت های پژوهش

باید چندین شاخص فنی معرفی شود تا روندهای قیمت سهام را به عنوان ورودی برای رونق بیشتر روند قیمت های سهام با دقت بالا نشان دهند. در این پژوهش تنها ۵ روز آینده قیمت سهام پیش بینی شده است که برای سرمایه گذاران سهام مناسب است. بهبود ساختار شبکه عصبی و گسترش زمان پیش بینی باید در نظر گرفته شود.

فهرست منابع

- ۱) حسین بدیعی؛ روح اله رضازاده، هادی محمودی. (۱۳۹۶). پیش‌بینی رفتار قیمتی سهام در بورس اوراق بهادار با استفاده از شبکه‌ی عصبی مصنوعی (مطالعه موردی شرکت پالایش نفت اصفهان)، فصلنامه مهندسی مالی و مدیریت اوراق بهادار، مقاله ۸، دوره ۸، شماره ۳۱، صفحه ۱۶۷-۱۸۵.
- 2) Li JC, Mei DC (2013) The risks and returns of stock investment in a financial market. *Phys Lett A* 377(9):663–670
- 3) Shen KY, Yan MR, Tzeng GH (2014) Combining VIKOR-DANP model for glamor stock selection and stock performance improvement. *Knowl Based Syst* 58(1):86–97
- 4) Pham HV, Cooper EW, Cao T, Kamei K (2014) Hybrid Kansei-SOM model using risk management and company assessment for stock trading. *Inf Sci* 256(1):8–24
- 5) Chen MY, Chen BT (2015) A hybrid fuzzy time series model based on granular computing for stock price forecasting. *Inf Sci* 294:227–241
- 6) Liu Y, Chen Y, Wu S, Peng G, Lv B (2015) Composite leading search index: a preprocessing method of internet search data for stock trends prediction. *Ann Oper Res* 234(1):77–94
- 7) Smailovic J, Grčar M, Lavrač N, Žnidarsič M (2014) Streambased active learning for sentiment analysis in the financial domain. *Inf Sci* 285(1):181–203
- 8) Li JC, Li C, Mei DC (2014) Effects of time delay on stochastic resonance of the stock prices in financial system. *Phys Lett A* 378(30–31):1997–2000
- 9) Edirisinghe NCP, Zhang X (2008) Portfolio selection under DEA-based relative financial strength indicators: case of US industries. *J Oper Res Soc* 59(6):842–856
- 10) Sumantyo R, Melati (2013) Effect analysis of fundamental factors toward cigarettes company's stock price that listed in Indonesia Stock Exchange (IDX) period 2008–2013. *Soc Sci Electron Publishing* 10(10):1–20
- 11) Murugesan C, Sakthi Priya E (2016) Investment in stock market: fundamental and technical analysis. *Int J Sci Res (IJSR)* 5(2):1986–1991.
- 12) Wang YC, Yu J, Wen SY (2014) Does fundamental and technical analysis rce investment risk for growth stock? An analysis of Taiwan stock market. *Int Bus Res* 7(11):24–34

- 13) Lee SJ, Lee DJ, Oh HS (2005) Technological forecasting at the Korean stock market: a dynamic competition analysis using Lotka– Volterra model. *Technol Forecast Soc Change* 72:1044–1057
- 14) Modis T (1999) Technological forecasting at the stock market. *Technol Forecast Soc Change* 62(3):173–202
- 15) Carter AP (1970) Technological forecasting and input–output analysis. *Technol Forecast* 1(4):331–345
- 16) Zhang HS, Shen XY, Huang JP (2016) Pattern of trends in stock markets as revealed by the renormalization method. *Phys A* 456:340–346
- 17) Kazem A, Sharifi E, Hussain FK, Saberi M, Hussain OK (2013) Support vector regression with chaos-based firefly algorithm for stock market price forecasting. *Appl Soft Comput* 13(2):947–958
- 18) Box GEP, Jenkins GM (1994) *Time series analysis: forecasting and control*, 3rd edn. Prentice Hall, Englewood Cliffs
- 19) Pai P-F, Lin C-S (2005) A hybrid ARIMA and support vector machines model in stock price forecasting. *Omega* 33(6):497–505
- 20) Wang J-Z, Wang J-J, Zhang Z-G, Guo S-P (2011) Forecasting stock indices with back propagation neural network. *Expert Syst Appl* 38(11):14346–14355.
- 21) Boyacioglu MA, Avci D (2010) An adaptive network-based fuzzy inference system (ANFIS) for the prediction of stock market return: The case of the Istanbul stock exchange. *Expert Syst Appl* 37(12):7908–7912
- 22) Cheng C-H, Chen T-L, Wei L-Y (2010) A hybrid model based on rough sets theory and genetic algorithms for stock price forecasting. *Inf Sci* 180(9):1610–1629
- 23) Hadavandi E, Shavandi H, Ghanbari A (2010) Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting. *Knowl Based Syst* 23(8):800–808
- 24) Bagheri A, Mohammadi Peyhani H, Akbari M (2014) Financial forecasting using ANFIS networks with quantum-behaved particle swarm optimization. *Expert Syst Appl* 41(14):6235–6250
- 25) Chen S-M (1996) Forecasting enrollments based on fuzzy time series. *Fuzzy Sets Syst* 81(3):311–319
- 26) Cheng C, Chen T, Teoh H, Chiang C (2008) Fuzzy time-series based on adaptive expectation model for TAIEX forecasting. *Expert Syst Appl* 34(2):1126–1132
- 27) Yu H-K (2005) Weighted fuzzy time series models for TAIEX forecasting. *Phys A* 349(3–4):609–624

- 28) Liu X, Ma X (2012) Based on BP neural network stock prediction. *J Curric Teach* 1(1):45–50
- 29) Babu AS, Reddy SK (2015) Exchange Rate Forecasting using ARIMA, neural network and fuzzy neuron. *J Stock Forex Trad* 4(03):1–5
- 30) Murkute A, Sarode T (2015) Forecasting market price of stock using artificial neural network. *IJCA* 124(12):11–15
30. Ye Q, Wei L (2015) The prediction of stock price based on improved wavelet neural network. *Open J Appl Sci* 05(04):115–120
- 31) Guo XC, Shang SH (2013) BP neural network research based on three convergence improved LM algorithm. *Appl Mech Mater* 303–306:1543–1546
- 32) Liu SH, Bi ZJ, Zhang W (2012) A radar fault prediction based on LM-BP neural network. *Appl Mech Mater* 241–244:293–297
- 33) Tan S, An Y, Wu Y, Zhang D (2016) Electromyography based handwriting recognition system using LM-BP Neural Network. In: 9th international conference on human system interactions (HSI)
- 34) Li F (2014) Research on prediction model of stock price based on LM-BP neural network. In: Proceedings of the international conference on logistics, engineering, management and computer science.
- 35) Battiti R (1992) First- and second-order methods for learning: between steepest descent and Newton's method. *Neural Comput* 4(2):141–166
- 36) Hagan MT, Menhaj MB (1994) Training feedforward networks with the Marquardt algorithm. *IEEE Trans Neural Netw* 5(6):989–993
- 37) Hagan MT, Demuth HB, Beale MH, De Jesu's O (1996) Neural network design, vol 20. PWS publishing company, Boston
- 38) Basheer IA, Hajmeer M (2000) Artificial neural networks: fundamentals, computing, design, and application. *J Microbiol Methods* 43(1):3–31.
- 39) Zhang L, Luo J, Yang S (2009) Forecasting box office revenue of movies with BP neural network. *Expert Syst Appl* 36(3):6580–6587
- 40) Pereira EN, Scarpin CT, Albino L, Teixeira J (2015) Hybrid wavelet model for time series prediction. *Appl Math Sci* 9(149):7431–743
- 41) Kolsrud DAG (2015) A time-simultaneous prediction box for a multivariate time series. *J Forecast* 34(8):675–693.
- 42) Runge J, Donner RV, Kurths J (2015) Optimal model-free prediction from multivariate time series. *Phys. Rev. E* 91(5):052909.

- 43) Sangjun W, Supakwong S, Thajchayapong S (2015) Prediction of financial time-series signals using a Trous Wavelet Transform. *Appl Mech Mater* 781:523–526.
- 44) Zhang X, Pang Y, Cui M, Stallones L, Xiang H (2015) Forecasting mortality of road traffic injuries in China using seasonal autoregressive integrated moving average model. *Ann Epidemiol* 25(2):101–106
- 45) Wasseja MM, Mwenda SN (2015) Analysis of the volatility of the electricity price in Kenya using autoregressive integrated moving average model. *Sci J Appl Math Stat* 3(2):47–57
- 46) Lin Y, Chen M, Chen G, Wu X, Lin T (2015) Application of an autoregressive integrated moving average model for predicting injury mortality in Xiamen, China. *BMJ Open* 5(12):e008491
- 47) Kang HS, Kim H, Lee J, Lee I, Kwak BY, Im H (2015) Optimization of pumping schle based on water demand forecasting using a combined model of autoregressive integrated moving average and exponential smoothing. *Water Sc Technol Water Supply* 15(1):188–195.
- 48) Zhang Z, Ma X, Yangb Y (2003) Bounds on the number of hidden neurons in three-layer binary neural networks. *Neural Netw* 16(7):995–1002
- 49) Liang X, Chen RC (2010) A unified mathematical form for removing neurons based on orthogonal projection and crosswise propagation. *Neural Comput Appl* 19(3):445–457
- 50) Funahashi KI (1989) On the approximate realization of continuous mappings by neural networks. *Neural Netw* 2(3):183–192
- 51) Chua CG, Goh ATC (2003) A hybrid Bayesian back-propagation neural network approach to multivariate modeling. *Int J Numer Anal Methods Geomech* 27(8):651–667
- 52) Mirchandani G, Cao W (1989) On hidden nodes for neural nets. *IEEE Trans Circuits Syst* 36(5):661–664
- 53) Sequin CH, Clay RD (1990) Fault tolerance in artificial neural networks. In: 1990 IJCNN international joint conference on neural networks
- 54) Jia J (2014) Financial time series prediction based on BP neural network. *Appl Mech Mater* 631–632:31–34
- 55) Yu S, Ou J (2009) Forecasting model of agricultural products prices in wholesale markets based on combined BP neural network- time series model. In: 2009 international conference on information management, innovation management and industrial engineering

56) Liang L, Shao F (2010) The study on short-time wind speed prediction based on time-series neural network algorithm. In: 2010 Asia-Pacific power and energy engineering conference

57) Yang S, Berdine G (2015) Model selection and model over-fitting. SWRCCC 3(12):52-55

58) Utkin LV, Wiencierz A (2015) Improving over-fitting in ensemble regression by imprecise probabilities. Inf Sci 317:315-328

یادداشت ها :

۱- نوعی از فرایند تصادفی است که غالباً جهت مدلسازی و پیش‌بینی انواع مختلفی از پدیده‌های طبیعی و اجتماعی به کار می‌رود (Autoregressive model).

۲- این مدل‌ها در سریهای زمانی برای فهم بهتر مدل یا پیش‌بینی آینده به کار می‌روند. این مدل‌ها در جایی که داده‌ها غیر ایستا (non-stationary) باشند به کار می‌روند. در این حالت با یک بار دیفرانسیل‌گیری (متناظر با جز "یکپارچه integrated non-stationary") بودن داده‌ها از بین می‌رود و امکان برآورد یک ARMA در داده‌های جدید به وجود می‌آید.

۳- خطای میانگین مربعات (MSE): روشی برای برآورد میزان خطاست که در واقع تفاوت بین مقادیر تخمینی و آنچه تخمین زده شده، است MSE. به دو دلیل تقریباً همه جا مثبت است (صفر نیست) یک اینکه تصادفی است و دوم به این دلیل که تخمین‌گراطلاعاتی که قابلیت تولید تخمین دقیق تری دارد را حساب نمی‌کند. پس این شاخص که مقداری همواره نامنفی دارد، هرچقدر مقدار آن به صفر نزدیکتر باشد، نشان دهنده میزان کمتر خطاست. MSE شامل واریانس تخمین‌گر و بایاس (سوگیری) است. برای یک برآوردگر غیر بایاس، MSE همان واریانس برآوردگر است. مثل واریانس، MSE همان واحدهای اندازه‌گیری را به عنوان مربع مقادیر تخمین زده شده، دارد. در مقایسه با انحراف معیار ریشه دوم گرفتن از MSE، خطای ریشه میانگین مربع یا انحراف معیار میانگین ریشه (خطای جذر میانگین مربعات) را ارائه می‌دهد. برای هر برآوردگر غیر بایاس، RSME ریشه دوم واریانس است که به عنوان خطای استاندارد شناخته می‌شود.