



فصلنامه علمی پژوهشی دانش سرمایه‌گذاری
سال هشتم / شماره سی‌ام / تابستان ۱۳۹۸

استخراج قواعد چند مرتبه به منظور معاملات سهام با استفاده از ساختار شبکه‌ای و یادگیری بازگشتی کیو

محمدرضا علیمرادی

دانش آموخته کارشناسی ارشد مهندسی صنایع-مهندسی مالی، دانشگاه تربیت مدرس

علی حسین زاده کاشان

استادیار دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس (نویسنده مسئول)
a.kashan@modares.ac.ir

تاریخ دریافت: ۹۶/۱۰/۰۳ تاریخ پذیرش: ۹۶/۱۲/۲۲

چکیده

معامله‌گران در بازار سهام به هنگام تصمیم‌گیری در مورد خرید یا فروش سهم علاوه بر اطلاعات روز جاری سهم، اطلاعات سهم در روزهای گذشته را نیز در نظر می‌گیرند. به منظور تقلید از نحوه‌ی تصمیم‌گیری معامله‌گران در امر سرمایه‌گذاری در سهام، الگوریتم قهرمانی در لیگ ورزشی مجهز به تیم‌هایی با ساختار شبکه‌ای به جهت استخراج قواعد چند مرتبه، توسعه داده شده است. قوانین چند مرتبه توسط الگوریتم استخراج می‌شوند که در آن هر قاعده علاوه بر اطلاعات روز جاری، حاوی اطلاعات روزهای گذشته نیز می‌باشد بنابراین یک حافظه به منظور ذخیره اطلاعات مفید در هر یک از قوانین ایجاد شده است. به منظور ارزیابی و بررسی عملکرد مدل ارائه شده از ۲۰ سهم از شرکت‌ها در بخش‌های مختلف صنعتی بازار بورس تهران استفاده شده است. در شبیه‌سازی سرمایه‌گذاری، مدل ارائه شده سود بیشتر یا ضرر کمتری را نسبت به مدل خرید و نگهداری و مدل برنامه‌نویسی شبکه ژنتیک ایجاد کرده است.

واژه‌های کلیدی: الگوریتم قهرمانی در لیگ ورزشی، قواعد چند مرتبه، تحلیل تکنیکال، یادگیری تقویتی.

۱- مقدمه

استراتژی رویایی برای تمام سرمایه‌گذاران بازار سهام، خرید در قیمت پایین و فروش در قیمت بالا می‌باشد. اما از آنجا که قیمت سهام تابعی از مجموعه عوامل شناخته شده و ناشناخته بوده و رفتاری تقریباً غیر قابل پیش‌بینی از خود نشان می‌دهد، دستیابی به چنین استراتژی بهینه، کاری دشوار و معمولاً غیر ممکن است. بطور کلی، برای پیش‌بینی قیمت سهام و تعیین زمان خرید و فروش از دو رویکرد، تحلیل تکنیکال و تحلیل بنیادی استفاده می‌شود. تحلیل بنیادی، تحلیلی است که در صدد یافتن ارزش ذاتی یک دارایی مانند سهام و پیش‌بینی روند آتی بر اساس مجموعه‌ای از عوامل و متغیرهای اقتصادی و غیر اقتصادی. از سوی دیگر تحلیل تکنیکال، مطالعه رفتارهای بازار با استفاده از نمودارها و با هدف پیش‌بینی روند آتی قیمت‌ها می‌باشد (مورفی، ۱۹۹۹). تحلیل‌گران تکنیکال مبنای مطالعات خود را بر این فرض قرار می‌دهند که الگوهای تاریخی قیمت‌های سهام در آینده تکرار می‌شوند و بنابراین از این الگوها می‌توان به منظور اهداف پیش‌بینی استفاده کرد. هدف هر دو روش پیش‌بینی حرکات سهام از دیدگاه‌های مختلف است. گروهی از محققان آکادمیک بر خلاف نظر فعالان بازارهای اوراق بهادار، سودمندی تحلیل تکنیکال را مورد انتقاد قرار داده‌اند. اساس این انتقادها بر دو حقیقت بنا نهاده شده‌اند: فرضیه بازار کارا و نظریه قدم زدن تصادفی. فرضیه بازار کارا بیان می‌دارد که ((قیمت‌ها همیشه اطلاعات موجود را بطور کامل منعکس می‌کنند)). این فرضیه نشان می‌دهد که هر تلاشی برای کسب سود با بهره‌گیری از اطلاعات موجود بیهوده است (فاما، ۱۹۷۰). کوتنر (۱۹۶۷) با تکیه بر تئوری قدم زدن تصادفی نشان داد که قیمت سهام دارای روند تغییرات کاملاً تصادفی است و لذا نمی‌توان بر اساس قواعد تجربی از پیش طراحی شده نوسانات بازار را پیش‌بینی نمود. در نظریه قدم زدن تصادفی یکی از مولفه‌های مهم بازار یعنی مردم فراموش شده است. مردم قیمت روز قبل را به یاد دارند و بر طبق آن عمل می‌کنند. برای درک عکس‌العمل‌های مردم به قیمت مراجعه می‌شود اما قیمت نیز بر عکس‌العمل‌های مردم تاثیر می‌گذارد (نیسون، ۲۰۰۱). فارغ از نتایج حاصل از مطالعات اولیه (کوتنر، ۱۹۶۷؛ فاما و بلوم، ۱۹۶۶؛ فاما، ۱۹۷۰؛ درایدن، ۱۹۷۰؛ جنسن و بنینگتون، ۱۹۷۰؛ کانیتگهام، ۱۹۷۳) صورت گرفته بر روی استفاده از قاعده در معاملات و بیان ناکارآمدی قواعد تحلیل تکنیکال در معاملات، معامله‌گران همچنان به استفاده از این قواعد پرداخته تا اینکه در دهه ۹۰ میلادی روند جدید از پژوهش‌ها بر روی استفاده از قواعد تکنیکال در معاملات انجام گرفت که نتایج مربوط به تحقیقات پیشین مبنی بر ناکارآمدی قواعد تکنیکال را رد می‌نمود (گیوولی و لاکونیشکوف، ۱۹۷۹؛ بزبمبندر و چان، ۱۹۹۵؛ براک، لاکونیشکوف و لبارون، ۱۹۹۲؛ هاتسون، دمسی و کیسی، ۱۹۹۶؛ سالیوان، تیمرمان و وایت، ۱۹۹۹؛ ونگ، ۱۹۹۷). پس از تحقیقات اولیه که از روش‌های سنتی و ساده برای تولید قواعد معاملاتی استفاده می‌کردند، در اواخر دهه ۹۰ میلادی سیر جدیدی از مطالعات پدید آمدند که از روش‌های محاسباتی پیشرفته تری برای تولید قواعد معاملاتی استفاده می‌کردند. بوئر (۱۹۹۴) با استفاده از الگوریتم ژنتیک قواعد معاملاتی را به صورت خودکار و سیستماتیک استخراج نموده و در بازار سهام نیویورک مورد آزمایش قرار داد. نتایج تحقیق بوئر بازده مازاد نسبت به روش خرید و نگهداری را نشان می‌داد. نیلی، ولر و دیتمار (۱۹۹۷) از برنامه نویسی ژنتیک برای استخراج قواعد معاملاتی استفاده کردند. آنها قاعده‌های معاملاتی را به صورت درخت‌های تصمیم

استخراج نموده و برای شش ارز مختلف به آزمایش گذاشتند. نیلی و ولر (۱۹۹۹) با استفاده از برنامه نویسی ژنتیک، قواعد معاملاتی را برای ۴ نرخ ارز در نظام مالی اروپا استخراج کردند و بر طبق نتایج قواعد معاملاتی در سه مورد از نرخهای ارز مورد بررسی دارای بازده مازاد قابل ملاحظه‌ای بوده است.

در سال‌های اخیر استفاده از روش‌های محاسبات نرم^۱ نظیر الگوریتم ژنتیک (چین و چن، ۲۰۱۰؛ چنگ، چن و وی، ۲۰۱۰)، الگوریتم برنامه‌نویسی ژنتیک (اصفهان‌پور و موسوی، ۲۰۱۱؛ براتیچ و همکاران، ۲۰۱۶)، برنامه نویسی شبکه ژنتیک (ایزومی و همکاران، ۲۰۰۶؛ چن و همکاران، ۲۰۰۹؛ مابو و همکاران، ۲۰۱۳؛ مابو، اوبایاشی و کوریموتو، ۲۰۱۵) و شبکه‌های عصبی (چانگ و همکاران، ۲۰۱۱؛ دش و دش، ۲۰۱۶) به منظور انجام معاملات سهام یا پیش‌بینی قیمت سهام، از موضوعات مورد توجه محققین بوده است.

الگوریتم قهرمانی در لیگ ورزشی، مجهز به تیم‌هایی با ساختار شبکه‌ای شده است که این ساختار شبکه‌ای بدلیل دارا بودن حافظه ضمنی عملکرد، ساختار فشرده و امکان استفاده مجدد از گره‌ها برای محیط‌های پویایی همچون بازار سهام مناسب می‌باشد. معامله‌گران سهام علاوه بر اطلاعات روز جاری، اطلاعات روزهای گذشته را به منظور انجام معاملات در نظر می‌گیرند. لذا به منظور آن که الگوریتم قهرمانی در لیگ ورزشی از نحوه‌ی تصمیم‌گیری معامله‌گران در امر سرمایه‌گذاری تقلید کند، از قوانین چند مرتبه^۲ معرفی شده توسط وانگ، مابو و هیراساوا (۲۰۱۰) استفاده می‌کند. یکی از ویژگی‌های قوانین چند مرتبه این است که هر قاعده علاوه بر اطلاعات موجود در روز جاری، حاوی اطلاعات روزهای گذشته می‌باشد لذا از اطلاعات روزهای گذشته به هنگام استخراج قوانین و تصمیم‌گیری در مورد سرمایه‌گذاری استفاده می‌شود. هر قاعده شامل دستور معاملاتی (خرید/فروش) و اطلاعاتی در مورد سهم در روز صدور دستور معاملاتی و روز قبل از صدور دستور معاملاتی است. در واقع قوانین از مرتبه‌ی دو می‌باشند که حاوی اطلاعات روز جاری و روز قبل از صدور دستور معاملاتی هستند. اگر دستور معاملاتی صادر شده در روز معاملاتی، خرید و روند بازار صعودی باشد در اینصورت این قاعده در مخزن خرید صعودی ذخیره می‌شود. به همین ترتیب قوانین بر اساس دستور معاملاتی و روند بازار در مخازن، خرید-صعودی، خرید-نزولی، فروش-صعودی و فروش-نزولی ذخیره می‌شوند. پس از استخراج قواعد و تعیین میزان برازندگی هر تیم، تیم‌ها بر اساس برنامه زمانی لیگ با یکدیگر مسابقه می‌دهند. در پایان هر هفته، هر تیم بر اساس نقاط ضعف و قوت خود در هفته گذشته و نقاط ضعف و قوت تیم حریف (تیمی که در هفته بعد با آن باید مسابقه بدهد) اقدام به اصلاح آرایش تیمی خود برای بازی در هفته بعد می‌کنند. در دوره آزمایش، به منظور سرمایه‌گذاری از میانگین درجه‌ی تطبیق داده‌های دوره‌ی آزمایش با قوانین ذخیره شده در مخازن قاعده استفاده می‌شود و در مورد خرید، فروش و یا عدم معامله تصمیم‌گیری می‌گردد. ساختار این نوشتار بدین صورت است که در بخش بعدی مفاهیم پایه‌ای الگوریتم قهرمانی در لیگ ورزشی مجهز به تیم‌هایی با ساختار شبکه‌ای و یادگیری کیو بازگشتی بطور مختصر بیان گردیده است. در بخش سوم الگوریتم پیشنهادی به منظور استخراج قواعد چند مرتبه بیان گردیده است. در بخش چهارم شبیه‌سازی سرمایه‌گذاری و نتایج بیان گردیده اند. بخش پنجم به نتیجه‌گیری و پیشنهادات آتی اختصاص یافته است.

۲- مفاهیم پایه‌ای الگوریتم قهرمانی در لیگ ورزشی


در این قسمت مفاهیم پایه در رابطه با الگوریتم قهرمانی در لیگ ورزشی مجهز به تیم‌هایی با ساختار شبکه‌ای بطور مختصر توضیح داده می‌شوند.

۲-۱- انواع گره

هر تیم شامل یک گرهی آغازین، تعدادی گرهی قضاوت و پردازش می‌باشد که این گره‌ها در ساختار شبکه‌ای هر تیم، به یکدیگر متصل شده‌اند. در ابتدا هر تیم بصورت تصادفی ایجاد می‌شود و تمامی ارتباطات میان گره‌ها در هر تیم نیز بصورت تصادفی ایجاد می‌شود. نقش گرهی آغازین در هر تیم تعیین اولین گره در حرکت میان گره‌های شبکه است. هر گرهی قضاوت یا پردازش شامل دو زیر گره می‌باشد. گره‌های قضاوت دارای یک تابع تصمیم‌گیر از نوع اگر-آنگاه و گره‌های پردازش شامل دستور معاملاتی می‌باشند.

۲-۲- ایجاد برنامه بازی‌های لیگ

جهت تولید برنامه‌ی زمانی برای مسابقات لیگ، ابتدا فرض می‌شود هر دو تیم در طول فصل فقط یک بازی با هم انجام می‌دهند. در پایان فصل هر یک از L تیم حاضر $L-1$ مسابقه انجام خواهد داد که این یعنی آنکه در مجموع $\frac{L(L-1)}{2}$ بازی در طول فصل انجام می‌پذیرد. زمانبندی دارای یک الگوریتم ساده می‌باشد و بعنوان مثال می‌توان آن را با استفاده از یک لیگ ورزشی متشکل از ۸ تیم نشان داد. با توجه به شکل ۱ در هفته اول جفت تیم‌ها را تشکیل می‌دهیم.



شکل ۱- نمایش زمانبندی لیگ در الگوریتم قهرمانی در لیگ ورزشی

در شکل (۱-a) تیم ۱ با تیم ۸، تیم ۲ با تیم ۷، تیم ۳ با تیم ۶ و تیم ۴ با تیم ۵ بازی می‌کنند. در هفته دوم یک تیم ثابت نگه داشته می‌شود، برای مثال تیم ۱، و دیگر تیم‌ها را در جهت ساعتگرد می‌چرخانیم (شکل ۱-b). در این هفته تیم ۱ با تیم ۷، تیم ۸ با تیم ۶ و به همین ترتیب برای سایر تیم‌ها نیز برنامه بازی در هفته دوم تعیین می‌شود. این روند تعیین برنامه زمانی بازی‌ها تا هفته هفتم ($L-1$) ادامه می‌یابد. اگر تعداد تیم‌ها (L) عددی فرد

باشد، یک تیم ساختگی اضافه می‌شود و در هر هفته، رقیبان تیم ساختگی بازی نخواهند داشت و استراحت می‌کنند.

۲-۳- تعیین تیم برنده در یک بازی

برنده یک بازی بر اساس مقایسه‌ی یک عدد تصادفی تولید شده با مقداری از یک تابع به دست می‌آید که با میزان قدرت آن تیم رابطه‌ی مستقیم دارد. یعنی شانس برد تیم قوی‌تر بیشتر است ولی در عین حال، شانس برنده شدن در یک بازی با یک تیم قوی‌تر، هم چنان باقی است. آرایش تیمی و میزان قدرت تیم i در هفته t را به ترتیب، با X_i^t و $f(X_i^t)$ نشان می‌دهند. فرض کنید تیم‌های i و j در هفته t با یکدیگر مسابقه می‌دهند. در این صورت احتمال برد تیم i در هفته t ، که با p_i^t نشان داده می‌شود از رابطه ۱ بدست می‌آید. بطور مشابه می‌توانیم p_j^t را تعریف نماییم. بدیهی است که $p_i^t + p_j^t = 1$ عدد حاصل از آن تابع، مرزی را در بازه $[0,1]$ ایجاد می‌نماید. اکنون عدد تصادفی تولید می‌گردد، در صورتیکه کوچکتر از p_i^t (مرز تعیین شده) باشد، تیم مورد نظر برنده‌ی آن مسابقه اعلام می‌گردد و در غیر اینصورت، بازنده است. اگر f بهترین مقدار برازندگی تا آن لحظه باشد، مقدار p_i^t از رابطه ۱ بدست می‌آید.

$$p_i^t = \frac{f(X_i^t) - f}{f(X_i^t) + f(X_j^t) - 2f} \quad (1)$$

چون مقدار f از قبل مشخص نمی‌باشد، لذا از رابطه ۲ برای محاسبه آن استفاده می‌شود که در آن B_i^t بهترین آرایش تیمی یافت شده تا هفته t می‌باشد.

$$f = \min_{i=1, \dots, L} \{f(B_i^t)\} \quad (2)$$

۲-۴- بازسازی آرایش جدید تیم

در الگوریتم قهرمانی در لیگ ورزشی، آنالیز عملکرد تیم در هفته قبل (در هفته t) بعنوان ارزیابی داخلی (توانایی‌ها/ضعف‌ها) مورد بررسی و آنالیز عملکرد هفته قبل (هفته t) تیمی که در هفته بعد (هفته $t+1$) با آن بازی دارد بعنوان ارزیابی خارجی (تهدیدات/فرصت‌ها) مورد بررسی قرار می‌گیرد. جهت مدل نمودن آنالیز ساختگی برای تیم i ، بمنظور ایجاد آرایش تیم در هفته $t+1$ ، اگر تیم i بازی را (به) از تیم j در هفته t برده (باخته) باشد، فرض می‌کنیم که موفقیت بدست آمده (عدم موفقیت) مستقیماً به خاطر توانمندی‌های (ضعف-های) تیم i ، و در نتیجه ضعف (توانمندی) تیم j باشد. حال بر اساس برنامه زمانبندی لیگ در هفته $t+1$ فرض می‌شود که مسابقه بعدی تیم i با تیم l می‌باشد. اگر تیم l برنده (بازنده) بازی با (از) تیم k در هفته t باشد، بنابراین این موفقیت (عدم موفقیت) و آرایش تیم ممکن است یک تهدید (فرصت) مستقیم برای تیم i باشد. چنین موفقیتی (شکستی) توسط توانمندی‌ها (ضعف‌ها) حاصل شده است. تمرکز بر روی توانمندی‌های (ضعف-

های) تیم l ، به ما روش شهودی جهت اجتناب از تهدیدهای بلقوه (جهت بدست آوردن مزایای فرصت‌های ممکن) را می‌دهد و می‌توان بر روی نقاط ضعف (توانمندی‌ها) تیم k تمرکز کرد.

جدول ۱- ماتریس فرضی تقسیم‌بندی آنالیز مسابقات


	اتخاذ استراتژی S/T تیم i برنده، تیم l برنده تمرکز بر روی	اتخاذ استراتژی S/O تیم i برنده، تیم l بازنده تمرکز بر روی	اتخاذ استراتژی W/T تیم i بازنده، تیم l برنده تمرکز بر روی	اتخاذ استراتژی W/O تیم i بازنده، تیم l بازنده تمرکز بر روی
S	نقاط ضعف تیم j	نقاط ضعف تیم j		
W			نقاط قوت تیم j	نقاط قوت تیم j
O		نقاط قوت تیم k		نقاط قوت تیم k
T	نقاط ضعف تیم k		نقاط ضعف تیم k	

بر اساس اتفاقات هفته گذشته، اقدامات ممکن بدست آمده برای تیم i از آنالیز مسابقات فرضی، در ماتریس SWOT جدول ۱ خلاصه شده است. برای تمامی تیم‌ها، جهت ایجاد یک آرایش تیمی مناسب برای بازی تیم در هفته $t+1$ ، آنالیز فوق صورت می‌گیرد. بعد از اتخاذ یک استراتژی مناسب با کمک ماتریس ساختگی SWOT، تیم‌ها برای برطرف کردن گپ‌های موجود در آرایش تیمی خود از دو نوع الگوریتم یادگیری که در ادامه توضیح داده خواهند شد، بهره می‌گیرند.

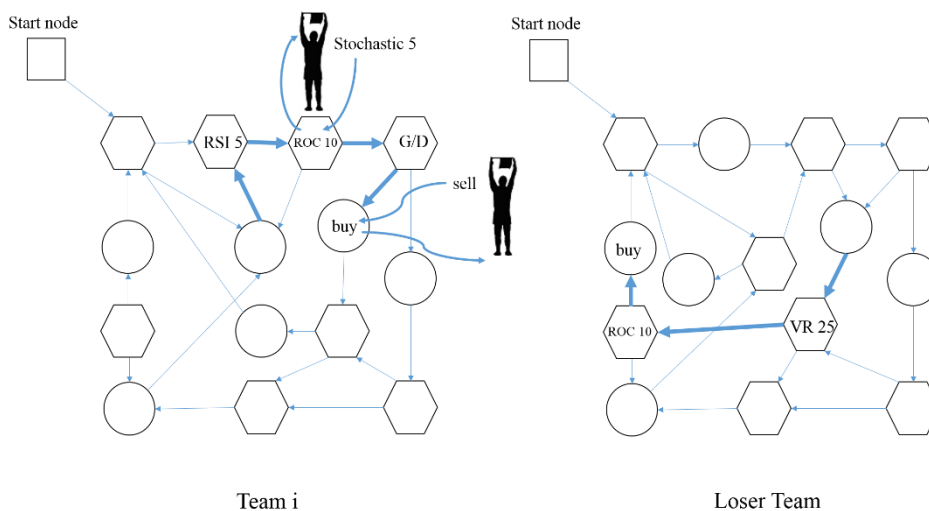
الگوریتم یادگیری از نقاط قوت تیم برنده: اگر فرض کنیم تعداد گام‌ها در حرکت میان گره‌های شبکه در هر هفته برابر m باشد، در اینصورت عدد صحیح n از میان اعداد صحیح $\{1, \dots, m\}$ و بردار $(step_{m_1}, \dots, step_{m_n})$ برداری از گام‌های تیم i به طول n ، بصورت تصادفی انتخاب می‌گردند. بردار $(step_{m_1}, \dots, step_{m_n})$ برداری از گام‌هایی می‌باشد که تیم i به منظور بر طرف کردن نقاط ضعف خود از طریق گام‌های متناظر در تیم برنده از آنها استفاده می‌نماید. برای هر گام $m_p (step_{m_p})$ که در آن $p=1, \dots, n$ ، عدد تصادفی V_{m_p} ، که در شرط $0 \leq V_{m_p} \leq \min(Length_{m_p}^i, Length_{m_p}^{winner})$ صدق کند، انتخاب و بعنوان تعداد تغییرات در هر گام m_p تعریف می‌شود. به تعداد V_{m_p} گره از میان گره‌های موجود در گام m_p از تیم i بصورت تصادفی انتخاب می‌کنیم. برای هر یک از گره‌های انتخاب شده دو حالت رخ خواهد داد. تابع در گره‌ی انتخاب شده، در میان توابع در گام متناظر در تیم برنده وجود ندارد. در این حالت بدین صورت عمل می‌کنیم که از میان گره‌های موجود در گام m_p در تیم برنده، گره‌ای به تصادف انتخاب و تابع آن در گره تعیین شده در آرایش تیمی i قرار می‌گیرد. در انتخاب گره‌ها در گام m_p تکرار مجاز نمی‌باشد. در این حالت وقتی تابع از تیم برنده به آرایش تیمی i منتقل می‌شود مقدار Q گره در آرایش تیمی i با استفاده از رابطه‌ی ۳ تعیین می‌گردد.

$$Q_i^{selected} = \max\{Q_i^{selected}, Q_{winner}^{selected}\} \quad (3)$$

اگر تابع در گره انتخاب شده برای تغییر، در گام m_p در تیم برنده وجود داشته باشد ارتباطات را از گره مورد نظر در تیم برنده در گام m_p یاد می‌گیرد. در شکل ۲ نحوه تغییر در آرایش تیمی در گام m_p برای تیم i با توجه به گام m_p در تیم برنده نمایش داده شده است.



شکل ۲- نحوه یادگیری از نقاط قوت تیم برنده



شکل ۳- نحوه یادگیری از نقاط ضعف تیم بازنده

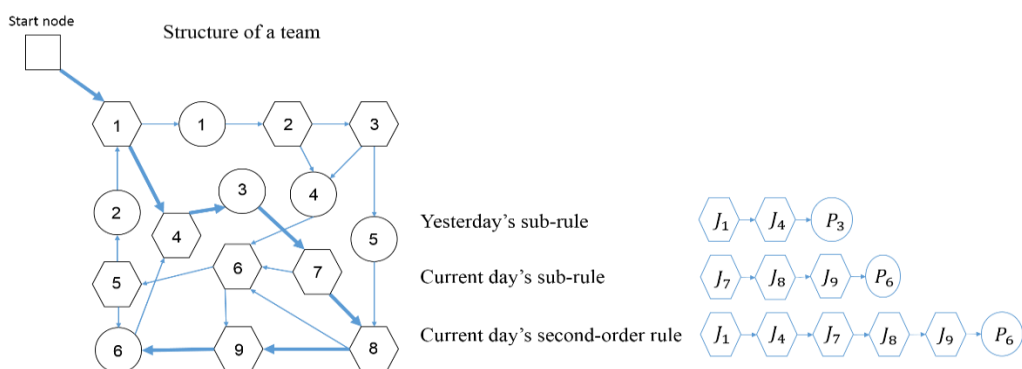
الگوریتم یادگیری از نقاط ضعف تیم بازنده: اگر فرض کنیم تعداد گام‌ها در حرکت میان گره‌های شبکه در هر هفته برابر m باشد، در اینصورت عدد صحیح n از میان اعداد صحیح $\{1, \dots, m\}$ و بردار $(step_{m_1}, \dots, step_{m_n})$ برداری از گام‌های تیم i به طول n به صورت تصادفی انتخاب می‌گردند. بردار $(step_{m_1}, \dots, step_{m_n})$ برداری از گام‌هایی می‌باشد که تیم i به منظور بر طرف کردن نقاط ضعف خود از طریق گام‌های متناظر در تیم بازنده، از آنها استفاده می‌نماید. برای هر گام m_p $(step_{m_p})$ که در آن $p=1, \dots, n$ یک عدد تصادفی V_{m_p} ، که در شرط $0 \leq V_{m_p} \leq \min(\text{Length}_{m_p}^i, \text{Length}_{m_p}^{loser})$ صدق کند، انتخاب و بعنوان تعداد تغییرات در هر گام m_p تعریف می‌شود. حال اگر در گام m_p در آرایش تیمی i مولفه‌ای از گام متناظر در تیم بازنده وجود داشته باشد آنگاه حداکثر به تعداد V_{m_p} بطور تصادفی و بدون تکرار، از میان توابع مشترک میان گام‌ها، توابعی را در آرایش تیمی i انتخاب می‌کنیم و با توابعی دیگر از انبار توابع جایگزین می‌شوند. بنابراین نقطه ضعف تیم بازنده در گام m_p در آرایش تیم i برطرف می‌شود. در این حالت مقدار Q در آرایش تیمی i تغییر نمی‌کند. اگر تعداد تغییرات در گام m_p از مقدار V_{m_p} کمتر باشد در این حالت به اندازه‌ی تعداد تغییرات باقیمانده، گره از میان گره‌های انتخاب نشده در گام m_p در آرایش تیمی i انتخاب و هر یک از ارتباطات این گره با گره‌های دیگر با احتمال p_q تغییر می‌کنند. در شکل ۳ نحوه تغییر در آرایش تیمی در گام m_p برای تیم i با توجه به گام m_p در تیم بازنده نمایش داده شده است. به منظور ایجاد آرایش تیمی جدید برای تیم i در هفته t برای بازی در هفته $t+1$ ، در ابتدا بهترین آرایش تیمی i تا هفته t بعنوان آرایش تیمی اولیه به منظور ایجاد تغییر، در آرایش تیمی i قرار می‌گیرد. با توجه به اینکه برای ایجاد آرایش تیمی جدید فقط بر بازی تیم i و بازی تیم رقیب، تیمی که در هفته $t+1$ با آن بازی می‌کند، در هفته t تمرکز می‌کنیم لذا حالات ممکن به شرح ذیل می‌باشد:

- (۱) تیم i و تیم l بازی‌های خود را به ترتیب در برابر تیم z و تیم k پیروز شده باشند. در این حالت تیم i در ابتدا با استفاده از نقاط ضعف تیم z اقدام به یادگیری و ایجاد آرایش تیمی جدید برای خود می‌کند. سپس با استفاده از یادگیری از نقاط ضعف k آرایش تیمی ایجاد شده را تقویت می‌کند.
- (۲) تیم i و تیم l بازی‌های خود را مقابل تیم z و تیم k واگذار کرده باشند. در اینصورت تیم i در ابتدا با استفاده از نقاط قوت تیم z اقدام به یادگیری و ایجاد آرایش تیمی می‌کند و سپس با یادگیری از نقاط قوت تیم k آرایش تیمی ایجاد شده را تقویت می‌کند.
- (۳) تیم i بازی را در برابر تیم z واگذار کرده باشد و تیم l در برابر تیم k به پیروزی رسیده باشد. در این حالت در ابتدا تیم i نقاط ضعف خود را از طریق یادگیری از نقاط قوت تیم z برطرف می‌کند و آرایش تیمی خود را تقویت می‌کند سپس با استفاده از نقاط ضعف تیم k ، اقدام به یادگیری و برطرف کردن این نقاط ضعف در تیم خود می‌کند.
- (۴) تیم i در برابر تیم z پیروز شده باشد و تیم l در برابر تیم k شکست خورده باشد. در این حالت ابتدا تیم i اقدام به یادگیری و برطرف کردن نقاط ضعف تیم z در آرایش تیمی خود کرده و سپس با استفاده از یادگیری از نقاط قوت تیم k آرایش تیمی خود را تقویت می‌کند.

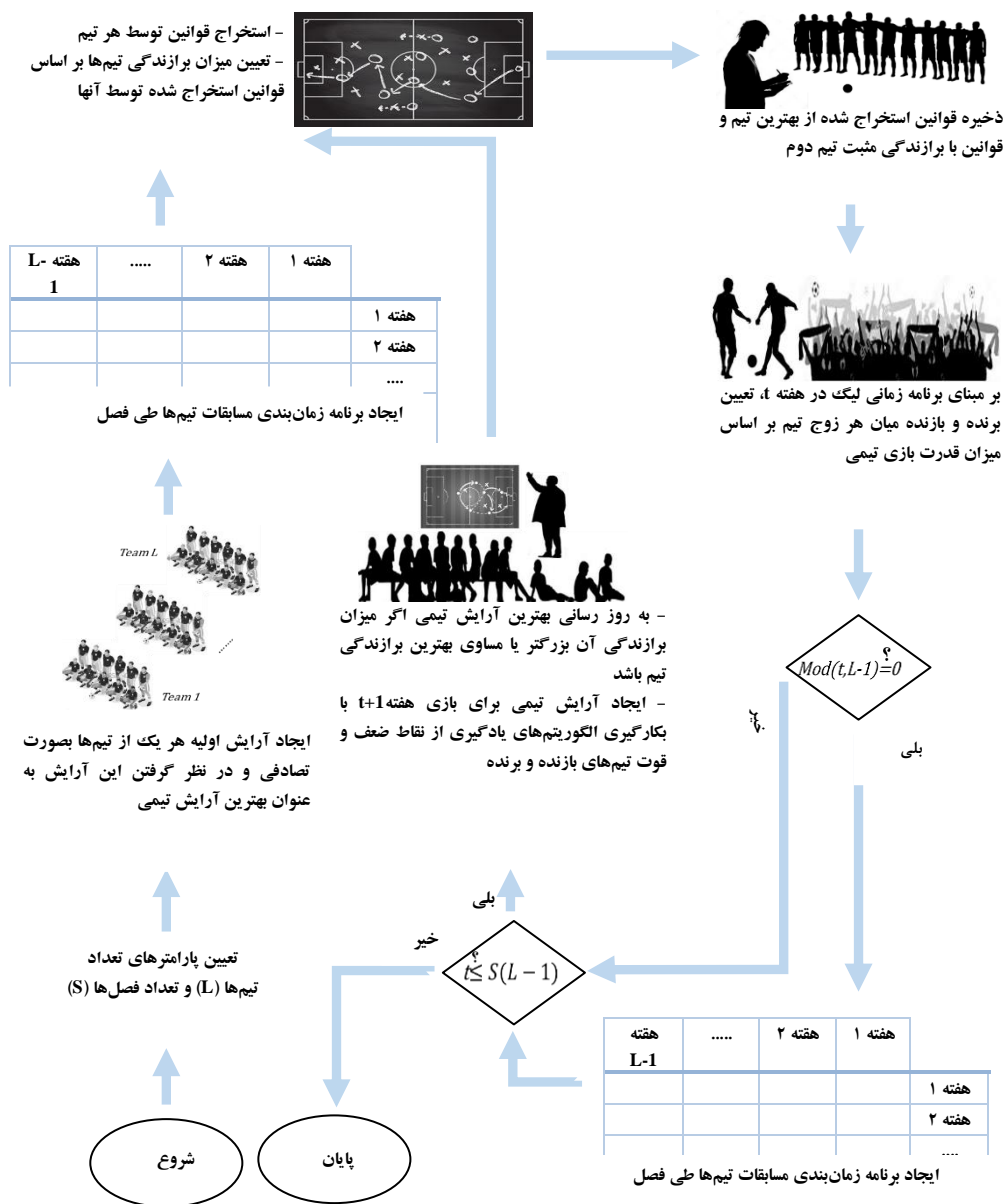
۳- استخراج قوانین چند مرتبه با استفاده از الگوریتم قهرمانی در لیگ ورزشی و نحوه انجام معاملات در این بخش جزئیات در مورد قواعد چند مرتبه، نحوه استخراج قواعد و نحوه سرمایه‌گذاری با استفاده از قواعد ذخیره شده توضیح داده می‌شوند.

۳-۱- تعریف قواعد چند مرتبه

زیر قاعده بصورت یک دنباله‌ی متوالی از گره‌های قضاوت و پردازش به همراه نتایج آنها تعریف می‌شود. یک قاعده‌ی چند مرتبه تشکیل شده است از تعدادی زیر قاعده که در آن گره‌های پردازش و نتایج آنها از زیر قاعده-های روزهای قبل حذف شده‌اند. مرتبه‌ی هر قاعده برابر با تعداد زیر قاعده‌ها تعریف می‌شود بعبارت دیگر مرتبه هر قاعده برابر است با تعداد روزهایی که اطلاعات قیمتی سهم در قاعده ذخیره شده است. بعنوان مثال یک قاعده دارای مرتبه‌ی N ، شامل اطلاعات روز جاری و $N-1$ روز گذشته می‌باشد. در این نوشتار از قواعد مرتبه دوم استفاده می‌شود. فرض کنید که، زیر قاعده روز گذشته تشکیل شده باشد از گره‌های قضاوت J_1 و J_4 و گره‌ی پردازش P_3 و زیر قاعده روز جاری بصورت J_7, J_8, J_9 و J_6 باشد در اینصورت قاعده‌ی مرتبه دوم برای امروز از گره‌های قضاوت J_1, J_4, J_7, J_8 و J_9 و گره‌ی پردازش P_6 تشکیل می‌شود. در شکل ۴ نحوه‌ی تشکیل قواعد بصورت شماتیک نمایش داده شده است.



شکل ۴- نحوه‌ی تشکیل قواعد



شکل ۵- فرآیند استخراج قواعد

۲-۳-۲-۳- جمع قواعد

در این قسمت نحوه استخراج قواعد و جمع آنها بصورت مختصر بیان می‌گردد. شکل ۵ فرآیند استخراج قواعد معاملاتی در دوره‌ی آزمایش را نشان می‌دهد.

۲-۳-۱- حرکت در میان گره‌ها

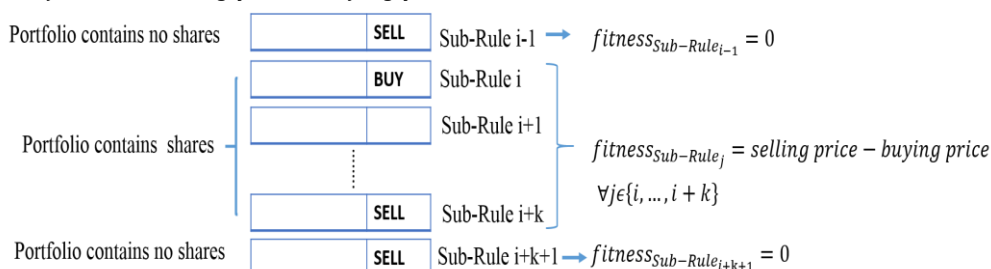
حرکت در میان گره‌ها در ساختار شبکه‌ای هر تیم بدین صورت انجام می‌گیرد که اگر گره‌ی جاری یک گره قضاوت باشد آنگاه بر اساس سیاست حریمانه ϵ یکی از دو زیر گره انتخاب می‌شود. نحوه‌ی انتخاب بر اساس سیاست حریمانه بدین صورت است که گره با مقدار Q بزرگتر با احتمال $1-\epsilon$ و یا یکی از گره‌ها بصورت تصادفی با احتمال ϵ انتخاب می‌گردد. در زیر گره انتخاب شده مقدار شاخص تکنیکال محاسبه و بر اساس نتیجه‌ی آن مسیر حرکت به گره‌ی بعدی تعیین می‌شود. اگر گره‌ی جاری یک گره پردازش باشد آنگاه مشابه انتخاب زیر گره در گره‌های قضاوت عمل می‌کنیم. پس از تعیین زیرگره و صدور دستور معاملاتی، با توجه به اینکه از زیرگره‌های پردازش تنها یک مسیر به یکی از گره‌های قضاوت وجود دارد لذا حرکت از این زیرگره به یکی از گره‌های قضاوت ادامه می‌یابد.

در هر هفته با حرکت میان گره‌ها در هر تیم، زیر قاعده‌ها بر اساس اطلاعات سهام روزانه ایجاد و قواعد مرتبه دو با استفاده از زیر قاعده‌های ایجاد شده در روز جاری و روز قبل ساخته می‌شوند.

۲-۲-۳- تعیین میزان برازندگی

تعیین میزان برازندگی برای زیر قاعده‌ها بدین صورت انجام می‌شود که اگر پورتفولیو شامل سهم نباشد و یک زیر قاعده با دستور معاملاتی خرید ایجاد شود در اینصورت میزان برازندگی این قاعده و قواعد استخراج شده پس از آن تا زمانیکه زیر قاعده‌ای با دستور فروش استخراج شود برابر و از طریق رابطه‌ی ۴ مقدار برازندگی قابل محاسبه است. مقدار برازندگی سایر زیر قواعد نیز صفر در نظر گرفته می‌شود. مقدار برازندگی قاعده‌ی درجه دو برابر با میزان برازندگی زیر قاعده روز جاری تعریف می‌شود (شکل ۶).

$$(۴) \text{fitness} = \text{selling price} - \text{buying price}$$



شکل ۶- نحوه تعیین برازندگی زیر قاعده‌ها

میزان برزندگی هر تیم در هر هفته برابر است با مجموع برزندگی قاعده‌های درجه دومی که توسط آن تیم استخراج شده‌اند. در هر هفته قواعد استخراج شده از تیم اول (تیمی که بیشترین مقدار برزندگی را در هفته کسب کرده است) و قواعدی از تیم دوم که مقدار برزندگی آنها مثبت باشد در مخازن قاعده ذخیره می‌شوند. قواعد مرتبه دو استخراج شده بر اساس نتیجه گرهی پردازش و بر اساس روند روز جاری در یکی از مخازن خرید-صعودی، خرید-نزولی، فروش-صعودی و فروش-نزولی ذخیره می‌شوند.

۳-۲-۳- تعیین روند بازار

روند حالتی است که قیمت برای یک زمان نسبتاً طولانی، یک جهت مشخص را در پیش گیرد. به منظور تعیین روند بازار با بکارگیری الگوریتم ژنتیک و با استفاده از مفاهیم ارزش روند^۳ و نرخ تغییر^۴ که در ادامه توضیح داده خواهند شد اقدام به خوشه بندی قیمت می‌کنیم. قیمت‌های سهم در دو خوشه‌ی صعودی و نزولی، خوشه بندی می‌شوند.

ارزش روند: تفاوت میان قیمت و میانگین متحرک، ارزش روند تعریف می‌شود و از رابطه‌ی ۵ قابل محاسبه می‌باشد.

$$T_n = \frac{P_n - MA_n}{MA_n} \quad (5)$$

که در آن P_n از رابطه‌ی ۶ بدست می‌آید.

$$P_n = \frac{O_n + H_n + L_n + C_n}{4} \quad (6)$$

بطوریکه، P_n میانگین قیمت سهم در روز n ، MA_n میانگین متحرک در روز n ، O_n ، H_n ، L_n و C_n به ترتیب، قیمت آغازین، قیمت حداکثر، قیمت حداقل و آخرین قیمت در روز n می‌باشند. برای محاسبه‌ی ارزش روند در این پژوهش از میانگین متحرک ۲۵ روزه استفاده شده است.

نرخ تغییر: بیان کننده درصد تغییر^۵ در ارزش، در طول یک دوره‌ی زمانی می‌باشد که بصورت رابطه ۷ محاسبه می‌شود.

$$\text{Rate of change} = \frac{\text{current price} - \text{previous price}}{\text{previous price}} \quad (7)$$

دوره‌ی زمانی در این قسمت یک روز معاملاتی در نظر گرفته شده است.

۳-۲-۴- یادگیری تقویتی


در این نوشتار از یادگیری بازگشتی کیو که ترکیبی از الگوریتم یادگیری سارسا و کیو می‌باشد بعنوان الگوریتم یادگیری تقویتی برای الگوریتم قهرمانی در لیگ ورزشی استفاده شده است به دلیل آنکه الگوریتم یادگیری بازگشتی کیو باعث افزایش سرعت یادگیری و در نتیجه استخراج قواعد معاملاتی بهتر می‌شود. در هر حرکت میان گره‌ها مقدار Q با توجه به رابطه‌ی ۸ بهنگام می‌شود که در آن مقدار $Q(s_t, a_t)$ مقدار Q برای

زیرگره a_t از گره s_t و $R(s_t)$ مقدار پاداش حاصل از صدور دستور معاملاتی است که برابر با اختلاف ارزش سهام فروش رفته و ارزش سهام خریداری شده بر اساس دستورهای معاملاتی می‌باشد. ضرایب α و γ اعدادی در بازه $[0,1]$ می‌باشند و به ترتیب نرخ یادگیری و نرخ تخفیف هستند.

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha [R(s_t) + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)] \quad (8)$$

در حرکت میان گره‌ها در شبکه اگر دستور معاملاتی خرید صادر شود بطوریکه هیچ سهامی در پورتفولیو موجود نباشد، در این صورت تمامی وضعیت‌ها (s_t) ، اقدامات (a_t) و پاداش‌های بعد از آخرین گره پردازش قبلی ذخیره و تمامی وضعیت‌ها و اقدامات و پاداش‌ها تا زمانیکه حرکات میان گره‌ها به گره پردازشی منتهی شود که اولین دستور فروش بعد از دستوری که منجر به خرید سهام شده، را به منظور بهنگام سازی مقادیر Q در حرکت بازگشتی ذخیره می‌کنیم. بعنوان مثال فرض کنید s_{t-n} اولین وضعیت بعد از آخرین گره پردازش منتهی شده به دستور معاملاتی خرید در شرایطی که سهام در پورتفولیو موجود نباشد، در نظر گرفته شود و s_{t+1} وضعیت منتهی به اولین دستور معاملاتی فروش، تحت شرایطی که سهام در پورتفولیو وجود دارد در نظر گرفته شود، تمامی وضعیت‌ها، اقدامات و پاداش‌ها بعد از s_{t-n} بصورت برداری مانند $(s_{t-n}^i, a_{t-n}^i, R_{t-n}^i, s_{t-n+1}^i)$ در M^i که در آن i اندیسی برای نمایش شماره گام می‌باشد تا وضعیت s_{t+1} برای بهنگام سازی، ذخیره شده و از رابطه‌ی ۹ برای بهنگام سازی مقادیر Q به صورت بازگشتی استفاده می‌شود. مقدار کیو برای s_{t+2} ، برای بهنگام سازی در حرکت بازگشتی، صفر در نظر گرفته می‌شود.

$$Q(s_{t-n}^i, a_{t-n}^i) \leftarrow Q(s_{t-n}^i, a_{t-n}^i) + \alpha_b [R^i(s_t) + \gamma_b \max_a Q(s_{t-n+1}^i, a_{t-n+1}^i) - Q(s_{t-n}^i, a_{t-n}^i)] \quad (9)$$



شکل ۷- یادگیری بازگشتی کیو

اگر یک گام شامل پنج گرهی قضاوت متوالی باشد برای بهنگام سازی مقادیر Q در حرکت بازگشتی برای گرهی پنجم جریمه در نظر گرفته می‌شود. لازم به ذکر است که به روز رسانی مقادیر کیو بصورت بازگشتی، فقط برای حرکت‌هایی استفاده می‌شود که در یک هفته اتفاق افتاده باشند بعنوان مثال اگر بر اساس اطلاعات در یک هفته خرید صورت بپذیرد ولی تا پایان هفته سیگنال فروش صادر نشود مقادیر کیو به صورت بازگشتی در این وضعیت به روز نمی‌شوند. در شکل ۷ نحوه بکارگیری یادگیری کیو بازگشتی بصورت شماتیک نشان داده شده است.

۳-۳- ایجاد سیگنال‌های خرید و فروش

به منظور بکارگیری قاعده‌های معاملاتی در سرمایه‌گذاری و صدور دستورهای معاملاتی در این نوشتار از درجه تطبیق استفاده می‌شود. مقدار تطبیق قاعده r در مخزن k ام با داده‌های قیمتی سهام در 2 روز متوالی بصورت رابطه ۱۰ تعریف می‌شود.

$$Match_k(d_p, d_c, r) = \frac{N_k(d_p, r) + N_k(d_c, r)}{N_k(r)} \quad (10)$$

که در آن $N_k(d_p, r)$ برابر است با تعداد نتایج توابع قضاوت در قسمت "اگر" زیر قاعده مربوط به روز گذشته که با داده‌های روز گذشته (d_p) مطابقت دارند و $N_k(d_c, r)$ برابر است با تعداد نتایج توابع قضاوت در قسمت "اگر" زیر قاعده مربوط به روز جاری که با داده‌های روز جاری (d_c) مطابقت دارند و $N_k(r)$ نیز تعداد توابع قضاوت در قسمت "اگر" قاعده r تعریف می‌شود. میانگین درجه تطبیق برای اطلاعات سهم در هر دو روز متوالی با استفاده از قاعده‌های موجود در مخزن k با استفاده از رابطه ۱۱ محاسبه می‌شود. R_k بیانگر تعداد قواعد حاضر در مخزن k در رابطه ۱۱ می‌باشد.

$$m_k(d_p, d_c) = \frac{1}{|R_k|} \sum_{r \in R_k} Match_k(d_p, d_c, r) \quad (11)$$

مقادیر میانگین و انحراف معیار مربوط به میانگین درجه تطبیق برای تمام روزهای متوالی در دوره آموزش با استفاده از رابطه‌های ۱۲ و ۱۳ جهت بکارگیری برای استخراج دستورهای معاملاتی در دوره آزمایش با استفاده از قواعد استخراج شده در دوره‌ی آموزش، محاسبه می‌شوند.

$$Mean_k = \frac{1}{|D_{training}|} \sum_{d \in D} m_k(d_p, d_c) \quad (12)$$

$$Std_k = \sqrt{\frac{1}{|D_{training}|} \sum_{d \in D} (m_k(d_p, d_c) - Mean_k)^2} \quad (13)$$

بر اساس روند بازار، مخازن را به دو دسته، دسته‌ی اول مخازن خرید و فروش در روند صعودی و دسته‌ی دوم مخازن خرید و فروش در روند نزولی تقسیم می‌کنیم. در هر روز در دوره‌ی آزمایش با استفاده از اطلاعات

سهام در روز جاری (d_c) و اطلاعات سهم در روز قبل (d_p) و با استفاده از زوج مخازن انتخاب شده میانگین‌های درجه‌ی تطبیق برای روز جاری محاسبه و در مورد سرمایه‌گذاری تصمیم‌گیری می‌شود.

اگر پورتفولیو شامل سهام باشد در اینصورت ابتدا بررسی می‌شود که آیا نگهداری سهام تصمیم مناسب است، لذا اگر میانگین درجه تطبیق در رابطه‌ی ۱۴ صدق کند آنگاه تصمیم مناسب نگهداری سهام می‌باشد در غیر اینصورت اگر رابطه‌ی ۱۴ برقرار نباشد آنگاه بررسی می‌شود که آیا فروش سهام تصمیم مناسب است، در واقع بررسی می‌شود که آیا درجه تطبیق در رابطه‌ی ۱۵ صدق می‌کند. اگر هیچ یک از روابط ۱۴ و ۱۵ برقرار نباشد آنگاه اقدامی انجام نمی‌دهیم.

حال اگر پورتفولیو شامل سهام نباشد در اینصورت در ابتدا بررسی می‌شود که آیا اطلاعات موجود متعلق به کلاس فروش می‌باشد به عبارت دیگر بررسی می‌کنیم که آیا عدم نگهداری سهام تصمیم مناسب است یا خیر، لذا اگر اطلاعات روز جاری و اطلاعات روز گذشته متعلق به کلاس فروش باشد آنگاه هیچ اقدامی انجام نمی‌گیرد یعنی میانگین درجه تطبیق در رابطه‌ی ۱۶ صدق کند، اگر اطلاعات روز جاری و اطلاعات روز گذشته متعلق به کلاس فروش نباشد آنگاه بررسی می‌کنیم که آیا خرید سهام تصمیم مناسب است. لذا اگر میانگین درجه تطبیق در رابطه صدق ۱۷ کند آنگاه اقدام به خرید سهام می‌کنیم. اگر میانگین درجه تطبیق در هیچ یک از روابط ۱۶ و ۱۷ صدق نکند در اینصورت هیچ اقدامی صورت نمی‌گیرد. در حقیقت با استفاده از شیوه‌ی بیان شده برای انجام معاملات در دوره آزمایش، دستورات معاملاتی از حالت دوگانه خرید و فروش به حالت سه‌گانه خرید، فروش و عدم معامله گسترش داده شده است زیرا در بعضی زمان‌ها در بازار سهام عدم انجام معامله یکی از بهترین تصمیم‌ها می‌باشد. در رابطه‌های ۱۴ تا ۱۷ مقادیر k_1 و k_2 به ترتیب مخازن خرید و فروش می‌باشند.

$$m_{k_1}(d_p, d_c) \geq Mean_{k_1} + \eta_1 Std_{k_1} \quad (14)$$

$$m_{k_2}(d_p, d_c) \geq Mean_{k_2} + \eta_2 Std_{k_2} \quad (15)$$

$$m_{k_2}(d_p, d_c) \geq Mean_{k_2} + \eta_3 Std_{k_2} \quad (16)$$

$$m_{k_1}(d_p, d_c) \geq Mean_{k_1} + \eta_4 Std_{k_1} \quad (17)$$

η ($\eta_1 = \eta_3 = .1$, $\eta_2 = \eta_4 = .4$) یک ضریب می‌باشد که میزان حساسیت تطبیق در صدور دستورهای معاملاتی را تنظیم می‌کند. اگر میزان این ضریب بزرگ انتخاب شود، شرایط بازار که بر تعداد بسیار زیادی قاعده منطبق شوند منجر به صدور دستور معاملاتی می‌گردد و بدین ترتیب شرایط تطبیق سخت‌گیرانه‌ای را در مدل برقرار می‌کند. البته این سیاست سختگیرانه می‌تواند منجر به از دست دادن بعضی فرصت‌های معاملاتی گردد. برعکس، اگر میزان ضریب کوچک انتخاب شود، شرایطی که بر تعداد کمتری قاعده منطبق شود نیز منجر به صدور دستورهای معاملاتی شده و لذا معاملات بیشتری در طول استفاده از مدل انجام می‌گیرد. استفاده از سیاست غیر سختگیرانه در مدل می‌تواند منجر به صدور دستورهای معاملاتی نابجا گردیده و اثر نامطلوبی بر سودمندی مدل داشته باشد.

۴- شبیه‌سازی

همانطور که در بخش‌های پیشین بیان گردید، در این نوشتار قواعد معاملاتی در دوره‌ی آموزش استخراج و ذخیره می‌شوند. در دوره‌ی آزمایش با استفاده از الگوریتم تطبیق، دستورهای معاملاتی از طریق قواعد استخراج شده صادر و بر اساس آنها سرمایه‌گذاری انجام می‌گیرد. به منظور بررسی کارایی مدل معرفی شده، سرمایه‌گذاری در ۲۰ سهم در بازار بورس تهران شبیه‌سازی می‌شود.

مدل ارائه شده برای استخراج قواعد معاملاتی بصورت کاملاً مجزا برای هر سهم اعمال می‌شود. با توجه به اینکه در بعضی از روزه‌های معاملاتی ممکن است سهم قابل معامله نباشد لذا تاریخ دقیقی برای تمامی سهم‌ها نمی‌توان بیان کرد ولی در حالت کلی تعداد روزه‌های دوره آموزش ۷۵۰ روز و تعداد روزه‌های دوره آزمایش ۲۵۰ روز می‌باشد به عبارت دیگر ۱۰۰۰ روز منتهی به تاریخ ۲۰ آگوست ۲۰۱۶ در این پژوهش مورد استفاده قرار گرفته است. برای مواجه نمودن مدل با شرایط متنوع بازاری در دوره آموزش و استخراج تعداد زیادی قاعده معاملاتی سهام به صورت کارآمد، دوره آموزش را از نظر زمانی به دوره‌های کوچکتر تقسیم می‌کنیم. تقسیم‌بندی دوره آموزش سبب می‌گردد که قواعد معاملاتی بصورت دقیق‌تر و با تعداد بسیار بالاتر استخراج شوند. دوره زمانی آموزش به ۳۰ دوره زمانی کوچک‌تر که هر کدام دارای ۲۵ روز هستند تقسیم می‌گردد.

سرمایه‌گذاری اولیه برای خرید سهام ده میلیون ریال است. هزینه کارمزد معاملاتی در این پژوهش در نظر گرفته شده است و به منظور ایجاد شرایط نزدیک‌تر سرمایه‌گذاری در پژوهش نسبت به سرمایه‌گذاری در دنیای واقعی هزینه‌های کارمزد معاملاتی در هزینه‌های مدل در نظر گرفته شده است. هزینه معاملات خرید برابر با ۵٪ ارزش معامله و هزینه معاملات فروش برابر با ۱٪ ارزش معامله در نظر گرفته شده است. هزینه‌های معاملاتی در هر معامله بر اساس قیمت سهام در روز انجام معامله محاسبه گردیده است. در این پژوهش به دلیل استفاده از داده‌های بازار بورس تهران که فروش استقراری در آن مجاز نمی‌باشد، فقط معاملات کلاسیک (خرید و فروش) در آن انجام می‌گیرد. بنابراین در یادگیری‌های تقویتی پاداش مورد استفاده در مدل فقط هنگام انجام معاملات فروش محاسبه شده و بیانگر میزان بازده حاصل از یک جفت معامله خرید و فروش می‌باشد. پاداش بصورت رابطه‌ی ۱۸ تعریف می‌شود.

$$reward = selling price - buying price \quad (18)$$

میزان جریمه برای گره‌ی قضاوت پنجم در هر گام به منظور بهنگام سازی مقدار Q در حرکت بازگشتی برابر است با:

$$Punishment_t = -0.1 \times stock price \quad (19)$$

جدول ۲- پارامترهای الگوریتم قهرمانی در لیگ ورزشی

تعداد تیم‌ها: ۲۰
تعداد گره‌ها: ۶۱ (تعداد گره‌های قضاوت: ۴۰، تعداد گره‌های پردازش: ۲۰، تعداد گره‌های آغازین: ۱)
تعداد فصل‌ها: ۲
تعداد هفته‌ها: ۱۹
$\alpha_b=9, \gamma_b=95, \alpha=1, \gamma=4, \varepsilon=1$

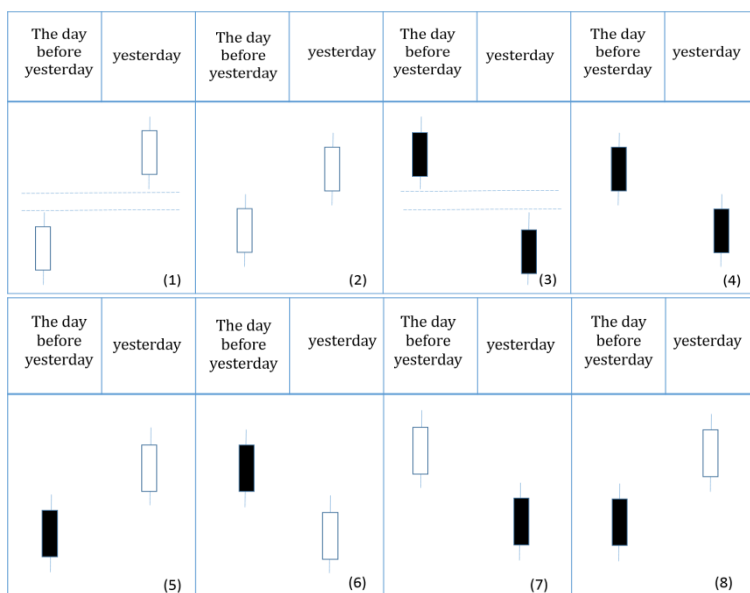
جدول ۳- پارامترهای الگوریتم برنامه نویسی شبکه ژنتیک

جمعیت هر نسل: ۱۰۰
(جمعیت تولید شده توسط جهش: ۳۸، جمعیت تولید شده توسط تقاطع: ۶۰، فرد برتر: ۱)
تعداد گره‌ها: ۶۱ (تعداد گره‌های قضاوت: ۴۰، تعداد گره‌های پردازش: ۲۰، تعداد گره‌های آغازین: ۱)
تعداد نسل‌ها: ۱۱۴۰
نرخ تقاطع (P_c): ۵، نرخ جهش (P_m): ۲.
$\alpha=1, \gamma=4, \varepsilon=1$

جدول ۴- پارامترهای الگوریتم ژنتیک

جمعیت هر نسل: ۱۰۰
(جمعیت تولید شده توسط جهش: ۳۰، جمعیت تولید شده توسط تقاطع: ۸۰، فرد برتر: ۱)
حداکثر تعداد تکرارها: ۱۰۰
نرخ تقاطع (P_c): ۸، نرخ جهش (P_m): ۳.

قیمت سهم برابر با قیمت پایانی سهم در روز t -ام است. پارامترهای استفاده شده در الگوریتم قهرمانی در لیگ ورزشی، برنامه‌نویسی شبکه ژنتیک و الگوریتم ژنتیک در جداول ۲، ۳ و ۴ بیان گردیده‌اند. متغیرهای تکنیکال استفاده شده در این پژوهش اندیکاتورهای ساده هستند. علت استفاده از متغیرهای تکنیکال ساده در این تحقیق آن است که هدف از طراحی مدل‌های قاعده محور تولید قواعد پیچیده از قواعد ساده می‌باشد. متغیرهای تکنیکال بکار رفته در این نوشتار در جدول ۵ بیان گردیده‌اند. نتایج مورد استفاده در تابع قضاوت برای نمودار شمعی ژاپنی در شکل ۸ نمایش داده شده است.



شکل ۸- نتایج قضاوت برای نمودارهای شمعی ژاپنی

جدول ۵- شاخص‌های تکنیکال

دوره سوم	دوره دوم	دوره اول	نام لاتین	متغیر تکنیکال
۲۵	۱۰	۵	Rate of Deviation (ROD)	نرخ انحراف
۲۵	۱۰	۵	Relative Strength Index (RSI)	شاخص قدرت نسبی
۲۵	۱۰	۵	Rate of change (ROC)	نرخ تغییر
۲۵	۱۰	۵	Volume Ratio	نسبت حجم معاملات
۲۵	۱۰	۵	Stochastic	نوسان نمای تصادفی
۲۵	۱۰	۵	Ranked Correlation Index (RCI)	شاخص همبستگی ترتیبی
-	۲۵	۵	Golden/ Dead Cross	تقاطع طلایی/ مرگ
-	۲۵	۵	Moving Average Convergence Divergence	همگرایی/ واگرایی میانگین متحرک
-	-	-	Candle Stick	شمعی ژاپنی

۱-۴- نتایج

ابتدا، الگوریتم قهرمانی در لیگ‌های ورزشی با ساختار تیمی شبکه‌ای با استفاده از داده‌های تاریخی مربوط به دوره آموزش تحت آموزش قرار می‌گیرد و قواعد معاملاتی استخراج شده از تیم اول و تعدادی از قوانین از تیم

دوم در هر هفته در مخازن ذخیره می‌شوند. سپس در دوره‌ی آزمایش با استفاده از میانگین درجه‌ی تطبیق، سیگنال‌های معاملاتی ایجاد و مورد استفاده قرار گرفته‌اند. در جدول ۶، مدل ارائه شده در این پژوهش با مدل برنامه‌نویسی شبکه ژنتیک ارائه شده توسط مابو و همکاران (۲۰۱۳) و مدل کلاسیک خرید و نگهداری مقایسه شده است. استراتژی خرید و نگهداری، تمام سرمایه اولیه در نظر گرفته شده در این پژوهش را در روز اول سرمایه‌گذاری، صرف خرید سهام نموده، آن را تا آخرین روز سرمایه‌گذاری، نگهداری کرده و در روز آخر سرمایه‌گذاری به قیمت روز به فروش می‌رساند. با توجه به جدول ۶، با مقایسه نتایج بدست آمده، مشاهده می‌شود که مدل برنامه‌نویسی شبکه ژنتیک برای سهام‌های مورد بررسی کارایی ندارد. از مواردی که با توجه به نتایج حاصل از مدل برنامه‌نویسی شبکه ژنتیک می‌توان دریافت، خرید و فروش در روندهای نزولی و انجام تعداد زیادی معامله است که با توجه به بالا بودن هزینه معاملاتی، باعث از بین رفتن سرمایه و در نتیجه بازده منفی مدل شده است. مدل سرمایه‌گذاری قاعده محور معرفی شده در ۱۸ مورد از ۲۰ مورد عملکرد بهتری نسبت به استراتژی معاملاتی خرید و نگهداری داشته است. این امر نشان می‌دهد که به کارگیری قواعد معاملاتی در سرمایه‌گذاری و سرمایه‌گذاری فعال در بازار سهام، دارای بازده و سود بالاتری نسبت به روش غیر فعال خرید و نگهداری می‌باشد.


جدول ۶- بازده حاصل از سرمایه‌گذاری

نام	مدل سرمایه‌گذاری قاعده محور		مدل برنامه‌نویسی شبکه ژنتیک		مدل خرید و نگهداری	
	سود (ریال)	نرخ سود (%)	سود (ریال)	نرخ سود (%)	سود (ریال)	نرخ سود (%)
اخابر	۵۶۴۳۷۴۱	۵۶/۴۴	-۷۲۵۵۳۵۳	-۷۲/۵۵	۵۶۴۳۷۴۱	۵۶/۴۴
البرز	۶۷۰۴۲۵۷	۶۷/۰۴	-۵۷۵۱۴۸۵	-۵۷/۵۱	۵۲۱۸۳۶۱	۵۲/۱۸
فاذر	۸۹۹۹۰۲۹	۸۹/۹۹	-۶۷۴۰۷۴۸	-۶۷/۴۱	۸۳۳۲۰۱۵	۸۳/۳۲
چکارن	۷۹۴۴۷۴۲	۷۹/۴۵	-۶۶۰۹۵۹۳	-۶۶/۱۱	۵۸۳۱۹۹۳	۵۸/۳۲
دکوثر	-۱۳۶۶۹۹	-۱/۳۷	-۷۵۶۸۹۶۶	-۷۵/۶۹	-۲۱۴۳۶۱	-۲/۱۴
فولاد	۴۰۶۳۱۰۱	۴۰/۶۳	-۷۲۳۹۰۶۶	-۷۲/۳۹	-۱۵۰۷۶۷	-۱/۵۱
حکشتی	۵۱۶۴۸	۰/۵۲	-۸۰۹۱۶۸۸	-۸۰/۹۲	-۷۷۰۰۳۰	-۷/۷۰
کاما	۸۲۳۶۱۰۸	۸۲/۳۶	-۵۶۱۶۳۰۰	-۵۶/۱۶	۶۰۸۰۳۸۸	۶۰/۸۰
کمرجان	۱۲۵۸۳۶۲	۱۲/۵۸	-۵۴۵۷۲۶۸	-۵۴/۵۷	-۱۵۰۳۳۲۹	-۱۵/۰۳
کطبیس	۶۴۷۹۷۷۳	۶۴/۸۰	-۶۵۴۰۶۶۱	-۶۵/۴۱	۲۸۸۸۶۸۹	۲۸/۸۷
کترام	۱۳۹۳۲۲۳	۱۳/۹۳	-۷۶۳۳۷۰۵	-۷۶/۳۴	۱۰۷۴۷۹۷	۱۰/۷۵
خبهنم	۳۳۳۹۱۷	۳/۳۴	-۵۳۸۱۳۸۲	-۵۳/۸۱	۲۳۱۸۶۴۳	۲۳/۱۹
پسهند	۴۱۹۷۳۹۹	۴۱/۹۷	-۶۵۱۴۱۹۳	-۶۵/۱۴	۱۰۴۹۳۹۵	۱۰/۴۹
غالبر	۴۹۴۳۶۳۰	۴۹/۴۴	-۷۷۲۸۳۴۴	-۷۷/۲۸	۳۵۹۹۱۶۱	۳۵/۹۹
سشرق	۱۶۷۸۴۶۵	۱۶/۷۸	-۷۳۳۰۸۴۸	-۷۳/۳۱	۱۱۶۷۱۲۷	۱۱/۶۷
ثنوسا	-۸۹۸۸۰۰	-۸/۹۹	-۷۹۵۷۳۷۶	-۷۹/۵۷	-۲۷۲۸۸۵۸	-۲۷/۲۹

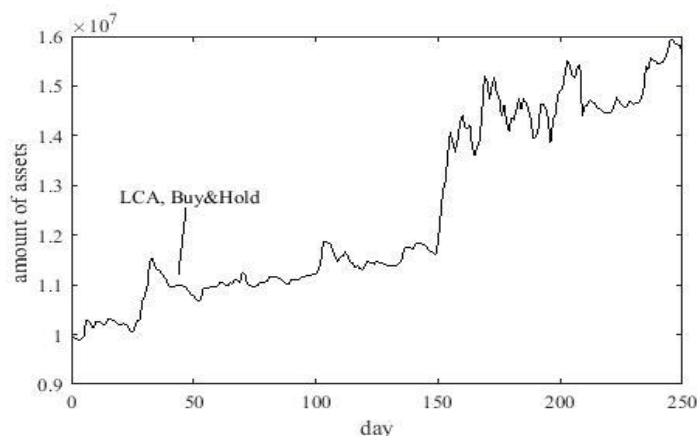
نام	مدل سرمایه‌گذاری قاعده محور		مدل برنامه‌نویسی شبکه ژنتیک		مدل خرید و نگهداری	
	سود (ریال)	نرخ سود (%)	سود (ریال)	نرخ سود (%)	سود (ریال)	نرخ سود (%)
شفارس	۱۲۲۲۲۲۲۲	۱۲۲/۲۲	-۴۸۶۲۹۹۶	-۴۸/۶۳	۱۳۳۸۷۱۱۵	۱۳۳/۸۷
شپنا	۲۶۴۴۵۷۱	۲۶/۴۵	-۶۱۷۰۴۸۷	-۶۱/۷۰	۴۶۷۹۹۳	۴/۶۸
تایرا	۲۴۷۱۴۰۶	۲۴/۷۱	-۷۸۷۸۲۷۴	-۷۸/۷۸	۷۱۹۹۳۲	۷/۳۰
وپاسار	-۳۸۱۰۶۴	-۳/۸۱	-۷۲۹۲۰۵۷	-۷۲/۹۲	-۱۶۰۹۴۵۹	-۱۶/۰۹

با توجه به شکل ۹ روند قیمتی سهم فاذر صعودی می‌باشد و در این بازه زمانی مدل خرید و نگهداری و مدل معاملاتی قاعده محور معرفی شده بازده مثبتی را کسب کرده‌اند. در ابتدای دوره قیمت سهم در یک روند نزولی می‌باشد که یک نوسان رو به بالا را تجربه کرده که پس از آن قیمت ریزش داشته است که مدل معاملاتی قاعده محور معرفی شده در این بازه‌ی زمانی از انجام معامله امتناع ورزیده است. مشابه اکثر معامله‌گران سهام در انتهای روند نزولی مدل معاملاتی قاعده محور اقدام به خرید سهام کرده است و هنگامی که قیمت سهم در حال افزایش بوده است سهام را نگهداری کرده است. در انتهای روند صعودی هنگامیکه سهم وارد یک ناحیه بدون روند می‌شود مدل معاملاتی معرفی شده اقدام به فروش سهام کرده است.

با توجه به شکل ۱۰ که روند قیمتی سهم اخبار را نشان می‌دهد، روند قیمتی سهم صعودی می‌باشد. مدل معاملاتی در روز اول اقدام به خرید سهام کرده است و تا اواخر دوره سهم را نگهداری کرده است. با توجه به اینکه روند قیمتی صعودی بوده است لذا رفتار الگوریتم معاملاتی مشابه مدل کلاسیک خرید و نگهداری بوده است.



شکل ۹- ارزش سهم فاذر (آبی) و ارزش سرمایه‌گذاری مبتنی بر مدل پژوهش در سهم فاذر (مشکی) در طول دوره آزمایش



شکل ۱۰- ارزش سهم اخبار (آبی) و ارزش سرمایه‌گذاری مبتنی بر مدل پژوهش در سهم اخبار (مشکی) در طول دوره آزمایش

همانگونه که در بخش ۳-۳ مطرح شد، به منظور استخراج قواعد معاملاتی در دوره‌ی آزمایش از سیاست سختگیرانه، به دلیل حذف دستورهای معاملاتی غلط که به علت نوسانات قیمت سهم ایجاد می‌شوند و به دلیل پرداخت هزینه معاملاتی کمتر به علت آنکه در بورس اوراق بهادار تهران هزینه‌های معاملاتی مقادیر قابل ملاحظه‌ای می‌باشند، استفاده شده است. بنابراین در تعدادی از سهم‌های مورد مطالعه در دوره‌ی آزمایش تعداد معاملات کم بوده است و این امکان استفاده از معیارهای ارزیابی عملکرد همچون معیارهای بازده مبتنی بر ریسک که معیار ریسک آنها ارزش در معرض ریسک و یا ارزش در معرض ریسک شرطی است را مقدور نمی‌سازد. با توجه به اینکه معیار ارزیابی عملکرد بر اساس تعداد معاملات سودده در برابر تعداد معاملات زیان‌ده، معیار مناسبی برای ارزیابی عملکرد مدل‌های معاملاتی نمی‌باشد (پاتل، ۲۰۱۰) لذا برای ارزیابی عملکرد مدل از نرخ بازده استفاده شده است و بنابراین یکی از مواردی که باید در پژوهش‌های آتی مورد مطالعه قرار بگیرد ارزیابی عملکرد مدل با استفاده از معیارهایی همچون بازده مبتنی بر ریسک می‌باشد.

۵- نتیجه‌گیری و پیشنهادات آتی

خرید و فروش سهام یکی از اصلی‌ترین فعالیت‌های سرمایه‌گذاری فعال در حوزه بازارهای مالی است. معامله‌گران به هنگام تصمیم‌گیری برای خرید یا فروش یک سهم، به منظور اتخاذ تصمیم مناسب، چندین روز معاملاتی را در نظر می‌گیرند. در این پژوهش به منظور تقلید از نحوه‌ی تصمیم‌گیری معامله‌گران، الگوریتم قهرمانی در لیگ ورزشی مجهز به تیم‌هایی با ساختار شبکه‌ای و یادگیری بازگشتی کیو به منظور استخراج قواعد چند مرتبه توسعه داده شده است. الگوریتم معاملاتی، قواعد چند مرتبه ایجاد می‌کند که این قواعد چند مرتبه اطلاعات مناسب بیشتری که متعلق به چندین روز معاملاتی است را شامل می‌شوند. الگوریتم معرفی شده در

دوره‌ی آموزش با مواجهه با شرایط گوناگون بازار قواعد متنوعی را استخراج و ذخیره می‌نماید. مواجهه با شرایط گوناگون در دوره‌ی آموزش این امکان را فراهم می‌آورد که در دوره‌ی سرمایه‌گذاری هنگام مواجهه با شرایط گوناگون بازار، دستورهای معتبرتری صادر گردد. به منظور بررسی عملکرد مدل معرفی شده نتایج حاصل از مدل با نتایج حاصل از برنامه‌نویسی شبکه ژنتیک دارای تجمیع قواعد و مدل خرید و نگهداری مقایسه شده است که نتایج شبیه‌سازی حاکی از آن است که مدل معرفی شده در تمامی موارد (۱۰۰٪) از مدل برنامه‌نویسی شبکه ژنتیک دارای تجمیع قواعد و در ۱۸ مورد از ۲۰ مورد (۹۰٪) سود بیشتر یا ضرر کمتری را نسبت به مدل خرید و نگهداری ایجاد کرده است. از مواردی که در پژوهش‌های آتی باید بدان پرداخته شود می‌توان به: (۱) با توجه به نحوه‌ی انتخاب زیرگره‌ها بر اساس سیاست حریصانه افسیلون ممکن است قوانین نامناسب استخراج گردند و در مخازن قاعده ذخیره شوند که باعث کاهش عملکرد مدل در هنگام اتخاذ تصمیم گردند لذا حرص قوانین نامناسب می‌تواند باعث بهبود عملکرد مدل شود. (۲) تعیین مرتبه‌ی قوانین چند مرتبه از مواردی است که می‌تواند عملکرد مدل را بهبود بخشد.

فهرست منابع

- * Bauer, R.J., 1994. Genetic algorithms and investment strategies. John Wiley & Sons.
- * Berutich, J.M., López, F., Luna, F. and Quintana, D., 2016. Robust technical trading strategies using GP for algorithmic portfolio selection. *Expert Systems with Applications*, 46, pp.307-315.
- * Bessembinder, H. and Chan, K., 1995. The profitability of technical trading rules in the Asian stock markets. *Pacific-Basin Finance Journal*, 3(2), pp.257-284.
- * Brock, W., Lakonishok, J. and LeBaron, B., 1992. Simple technical trading rules and the stochastic properties of stock returns. *The Journal of finance*, 47(5), pp.1731-1764.
- * Chang, P.C., Liao, T.W., Lin, J.J. and Fan, C.Y., 2011. A dynamic threshold decision system for stock trading signal detection. *Applied Soft Computing*, 11(5), pp.3998-4010.
- * Chen, Y., Mabu, S., Shimada, K. and Hirasawa, K., 2009. A genetic network programming with learning approach for enhanced stock trading model. *Expert Systems with Applications*, 36(10), pp.12537-12546.
- * Cheng, C.H., Chen, T.L. and Wei, L.Y., 2010. A hybrid model based on rough sets theory and genetic algorithms for stock price forecasting. *Information Sciences*, 180(9), pp.1610-1629.
- * Chien, Y.W.C. and Chen, Y.L., 2010. Mining associative classification rules with stock trading data—A GA-based method. *Knowledge-Based Systems*, 23(6), pp.605-614.
- * Cootner, P. H., 1967. The random character of stock market prices. Cambridge, Mass, M.I.T. Press.
- * Cunningham, S.W., 1973. The predictability of British stock market prices. *Applied Statistics*, 22(3), pp.315-331.
- * Dash, R. and Dash, P.K., 2016. A hybrid stock trading framework integrating technical analysis with machine learning techniques. *The Journal of Finance and Data Science*, 2, pp. 42-57.
- * Dryden, M.M., 1970. Filter tests of UK share prices. *Applied Economics*, 1(4), pp.261-275.
- * Esfahanipour, A. and Mousavi, S., 2011. A genetic programming model to generate risk-adjusted technical trading rules in stock markets. *Expert Systems with Applications*, 38(7), pp.8438-8445.

- * Fama, E.F. and Blume, M.E., 1966. Filter rules and stock-market trading. *The Journal of Business*, 39(1), pp.226-241.
- * Fama, E.F., 1970. Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, 25(2), pp.383-417.
- * Givoly, D. and Lakonishok, J., 1979. The information content of financial analysts' forecasts of earnings: Some evidence on semi-strong inefficiency. *Journal of Accounting and Economics*, 1(3), pp.165-185.
- * Hudson, R., Dempsey, M. and Keasey, K., 1996. A note on the weak form efficiency of capital markets: The application of simple technical trading rules to UK stock prices-1935 to 1994. *Journal of Banking & Finance*, 20(6), pp.1121-1132.
- * Izumi, Y., Yamaguchi, T., Mabu, S., Hirasawa, K. and Hu, J., 2006, July. Trading rules on the stock markets using genetic network programming with candlestick chart. In 2006 IEEE International Conference on Evolutionary Computation (pp. 2362-2367). IEEE.
- * Jensen, M.C. and Benington, G.A., 1970. Random walks and technical theories: Some additional evidence. *The Journal of Finance*, 25(2), pp.469-482.
- * Kashan, A.H. and Karimi, B., 2010, July. A new algorithm for constrained optimization inspired by the sport league championships. In IEEE Congress on Evolutionary Computation (pp. 1-8). IEEE.
- * Kashan, A.H., 2009, December. League Championship Algorithm: A New Algorithm for Numerical Function Optimization. In SoCPaR (pp. 43-48).
- * Kashan, A.H., 2011. An efficient algorithm for constrained global optimization and application to mechanical engineering design: League championship algorithm (LCA). *Computer-Aided Design*, 43(12), pp.1769-1792.
- * Kashan, A.H., 2014. League Championship Algorithm (LCA): An algorithm for global optimization inspired by sport championships. *Applied Soft Computing*, 16, pp.171-200.
- * Kashan, A.H., Karimiyan, S., Karimiyan, M. and Kashan, M.H., 2012, November. A modified League Championship Algorithm for numerical function optimization via artificial modeling of the "between two halves analysis". In *Soft Computing and Intelligent Systems (SCIS) and 13th International Symposium on Advanced Intelligent Systems (ISIS)*, 2012 Joint 6th International Conference on (pp. 1944-1949). IEEE.
- * Mabu, S., Hirasawa, K., Obayashi, M. and Kuremoto, T., 2013. Enhanced decision making mechanism of rule-based genetic network programming for creating stock trading signals. *Expert Systems with Applications*, 40(16), pp.6311-6320.
- * Mabu, S., Obayashi, M. and Kuremoto, T., 2015. Ensemble learning of rule-based evolutionary algorithm using multi-layer perceptron for supporting decisions in stock trading problems. *Applied Soft Computing*, 36, pp.357-367.
- * Murphy, J. J., 1999. *Technical analysis of the financial markets: a comprehensive guide to trading methods and applications*. New York, New York Institute of Finance.
- * Neely, C., Weller, P. and Dittmar, R., 1997. Is technical analysis in the foreign exchange market profitable? A genetic programming approach. *Journal of financial and Quantitative Analysis*, 32(4), pp.405-426.
- * Neely, C.J. and Weller, P.A., 1999. Technical trading rules in the European monetary system. *Journal of International Money and Finance*, 18(3), pp.429-458.
- * Nison, S., 2001. *Japanese candlestick charting techniques: a contemporary guide to the ancient investment techniques of the Far East*. New York, New York Institute of Finance.

- * Patel, M. (2010). Trading with Ichimoku clouds: the essential guide to Ichimoku Kinko Hyo technical analysis.
- * Sullivan, R., Timmermann, A. and White, H., 1999. Data-snooping, technical trading rule performance, and the bootstrap. *The journal of Finance*, 54(5), pp.1647-1691.
- * Wang, L., Mabu, S., Ye, F. and Hirasawa, K., 2010, August. Generalized rule accumulation based on Genetic Network Programming considering different population size and rule length. In *SICE Annual Conference 2010, Proceedings of* (pp. 2631-2636). IEEE.
- * Wong, M.C.S., 1997. Fund management performance, trend-chasing technical analysis and investment horizons: a case study. *Omega*, 25(1), pp.57-63.

یادداشت‌ها

¹ Soft computing

² Multi-order rule

³ Trend Value

⁴ Rate of change

⁵ Percentage Change