

سیستم استنتاج نوروفارازی برای معاملات بسامد بالا با استفاده از مدل مشاهده درون-روزانه

علی صالح‌آبادی^۱، سجاد فرازمند^{۱*}

چکیده: هدف اصلی این مقاله پیش‌بینی سری زمانی قیمت سکه برای انجام معاملات بسامد بالا است. بدین منظور، نوعی شبکه عصبی-فارازی معرفی می‌شود که به کمک استدلال فارازی و ترکیب آن با قابلیت شناسایی الگوی شبکه‌های عصبی پیش‌بینی‌هایی ارائه می‌دهد و بر مبنای پیش‌بینی‌ها، معاملات بسامد بالا انجام می‌شود. برای پالایش ورودی‌های غیرضروری در فرایند آموزش، نوعی مدل نوسان مبتنی بر رخداد، پیشنهاد و به انفیس متصل شده است. مدل‌های پژوهش با داده‌های قیمت سکه در بازه زمانی خرداد ۱۳۹۳ تا اردیبهشت ۱۳۹۵ آزمون شد. نتایج آزمون‌ها نشان می‌دهد بر اساس معیارهای نرخ موفقیت، عامل سود، نسبت بازدهی و نسبت شارپ، مدل نوسان‌پذیری مبتنی بر رخداد موجب می‌شود سیستم انفیس، ورودی‌های مناسب‌تری دریافت کند. همچنین، ترکیب انفیس با مدل نوسان مبتنی بر رخداد، برای پیش‌بینی و انجام معاملات بسامد بالا منجر به کسب نرخ موفقیت ۶۹ درصدی می‌شود.

واژه‌های کلیدی: انفیس، شبکه عصبی فارازی، مدل نوسان‌پذیری، بازارهای مالی، معامله‌های بسامد بالا.

JEL: C32, C45, G15, G24

۱. استادیار گروه مدیریت دانشگاه امام صادق (ع)، تهران، ایران

۲. دانشجوی دکتری مدیریت مالی، دانشگاه شهید بهشتی، تهران، ایران

تاریخ دریافت: ۱۳۹۵/۰۸/۱۴ تاریخ پذیرش: ۱۳۹۵/۱۲/۲۰

E-mail: S_farazmand@sbu.ac.ir نویسنده مسئول: سجاد فرازمند

نحوه استناد به این مقاله: صالح‌آبادی، ع.، و فرازمند، س. (۱۳۹۶). سیستم استنتاج نوروفارازی برای معاملات بسامد بالا با استفاده از مدل مشاهده درون-روزانه. *فصلنامه مدلسازی ریسک و مهندسی مالی*، ۱(۱)، ۸۰-۹۷.

مقدمه

معاملات بسامد بالا شاخه جدیدی در حوزه پیش‌بینی و انجام معاملات است. حدود ۷۰ درصد حجم کل معاملات بازار نزدک را این معاملات شامل می‌شوند (براگارد، هندرشات و ریوردان، ۲۰۱۴). علی‌رغم تعداد زیاد پژوهش‌ها، تعریفی واحد از معاملات بسامد بالا وجود ندارد. با وجود این، از جمله مهم‌ترین ویژگی‌های این نوع معاملات می‌توان، به تعداد زیاد معاملات، دوره نگهداری کوتاه و بستن موقعیت‌های معاملاتی به صورت روزانه اشاره کرد (زانکوا، ۲۰۱۶).

پژوهشگران این حوزه، اغلب با مدل سازی‌های پیچیده ریاضی و اعمال فرضیه‌های زیاد بر بازار به پیش‌بینی می‌پردازند اما به دلیل پیچیدگی‌های ذاتی بازار نرخ موفقیت بالایی حاصل نمی‌شود. با وجود این، نظریه‌های مالی بسیاری، مانند نظریه داو ادعا می‌کنند علی‌رغم تأثیرگذاری اطلاعات، اخبار و عوامل خارجی بر معاملات، بازارهای مالی تمایل دارند از الگوهایی خاص پیروی کنند (مورفی ۱۹۸۸) و می‌توان سودآوری معاملات را افزایش داد (دراکوگنا، جنکی، مولر، و اولسن، ۲۰۰۱). برخی نظریه‌ها با پیش‌بینی پذیر بودن بازارهای مالی در تنافض هستند. بر اساس نظریه بازار کارا، قیمت‌های فعلی شامل تمام اطلاعات در دسترس در بازار می‌شود و درنتیجه، امکان کسب بازده مازاد در معاملات بسامد بالا را تأیید نمی‌کنند.

شولمیستر (۲۰۰۹) نشان داد که پس از دهه ۹۰ میلادی سیستم‌های معاملاتی مبتنی بر تحلیل تکنیکال در چارچوب زمانی روزانه سودآور نیستند. انتخاب چارچوب زمانی ۳۰ دقیقه‌ای نیز فقط تا سال ۲۰۰۰ سودآوری ایجاد می‌کند و پس از آن تا سال ۲۰۰۶ سودآوری سیستم‌های تکنیکال از بین می‌رود. وی افزایش کارایی یا بسامد روندهای معاملاتی را دلیل این امر می‌داند. کرنز، کالزا و نومایواکا (۲۰۱۰) نشان دادند که با در نظر گرفتن هزینه معاملاتی، سودآوری معاملات بسامد بالای جسوانه در مقایسه با بازده مورد انتظار از این معاملات، بسیار کم است. رچنین و ستریت (۲۰۱۳) با آزمون‌های تجربی نشان دادند برای تصحیح قیمت‌ها و رسیدن به کارایی به ۳۰ دقیقه زمان نیاز است. با وجود این آن‌ها استراتئی‌هایی سودآور در این چارچوب زمانی را بررسی و ارائه نکردند.

رونده تغییر چارچوب زمانی در پژوهش‌ها نشان می‌دهد برای سودآوری می‌توان به چارچوب‌های زمانی کوتاه‌تر توجه کرد، همچنین به مبحث کنترل نوسان‌پذیری سیستم‌ها کمتر پرداخته شده است. از این‌رو، در مقاله حاضر تلاش می‌شود با نگاهی نو سیستم معاملاتی به همراه مدل کنترل نوسان‌پذیری با رویکرد مبتنی بر رخداد طراحی و ارائه شود. درواقع این مقاله با توجه به عامل نوسان‌پذیری و بررسی تغییرات بیشتر از حدود آستانه‌ای، به طراحی و بررسی سیستم معاملاتی می‌پردازد و در تکمیل پژوهش‌های پیشین است. اولین ویژگی این مقاله

به کارگیری سیستم انفیس برای معاملات بسامد بالا دورن-روزانه است. به کارگیری این روش در حوزه مورد پژوهش در ایران دارای نوآوری است. دومین ویژگی آن، به کارگیری مدل مشاهده تأثیرات فصلی روزانه (ایسام) است که روشی نوین برای کنترل نوسان پذیری با رویکرد مبتنی بر رخداد است. همچنین مدل ایسام به مدل مشاهده متوسط روزانه^۱ (اییام) تعیین داده می شود که تخمینی از نوسان متوسط روزانه ارائه می کند. کسب نرخ موفقیت بالاتر از ۵۰ درصد نشان دهنده موفقیت سیستم معاملاتی است.

در این مقاله، دربخش دو پیشینهٔ پژوهش بیان می شود. روش پژوهش در بخش سه ارائه می شود. بخش چهار به موضوع داده ها و یافته های پژوهش اختصاص یافته است. نتیجه گیری و پژوهش های آتی نیز در بخش پنجم مقاله بیان می شود.

پیشینهٔ پژوهش

مدل های متفاوتی برای انجام معاملات در بازارهای مالی ارائه شده است. مدل های مزبور تلاش می کنند با شناخت تغییرات قیمت و درنتیجه پیش بینی آن به سیستم های معاملاتی سودآور دست یابند. با وجود این پیچیدگی داده های مالی موفقیت مدل ها را با چالش مواجه می کند. زاده، واضح نظریهٔ منطق فازی، در مواردی که پدیدهٔ موربدبررسی پیچیدگی زیادی دارد پیشنهاد می کند، به جای استفاده از روش های سنتی از سیستم های فازی استفاده شود (زاده، ۱۹۷۵). پژوهش های بسیاری نیز شبکه های عصبی مصنوعی را به دلیل توانایی آن ها در یادگیری الگوهای موجود در داده ها، از جمله بهترین مدل های کاربردی در حوزه مالی بیان می کنند (سانگ، ۲۰۰۹؛ ساهین، ۲۰۱۲). ترکیب سیستم های فازی و شبکه های عصبی مصنوعی منتج به ایجاد سیستم استنتاج عصبی-فازی تطبیقی (انفیس) شده است که مزایای سیستم های فازی و شبکه های عصبی به صورت توأم، داراست. آتسالیکیس و والاونیس (۲۰۰۹) کارایی انفیس در پیش بینی قیمت سهام را با پانزده روش پیش بینی دیگر بررسی کردند. کسب نرخ موفقیت ۶۸ درصدی در این پژوهش نشان دهنده برتری انفیس نسبت به روش های مشابه پیش بینی قیمت بوده است. این برتری در پژوهش های دیگری نیز نشان داده شده است (چن، یینگ و پن، ۲۰۱۰؛ ملین، ساتا، کاستیلو و ساریا، ۲۰۱۲؛ وی، چنگ و پن، ۲۰۱۴).

دمستر، پین، راماها و تامپسون (۲۰۰۱)، از الگوریتم های یادگیرنده برای طراحی سیستم های معاملاتی در چارچوب داده های درون روزانه استفاده کردند. نتایج پژوهش آن ها

نشان داد با وجود هزینه معاملات، سیستم‌های معاملاتی با الگوریتم‌های یادگیرنده سودآوری قابل توجهی ندارند.

آراجو، اولیورا و مریا (۲۰۱۵) مدلی ترکیبی برای پیش‌بینی سری‌های زمانی مالی بسامدبالا در بازار سرمایه ارائه کردند. آن‌ها از مدل نرون خطی افزایش-کاهشی جدیدی با استفاده از روش مبتنی بر گرادیان استفاده کردند و مدل پیشنهادی را با سه سری زمانی بسامدبالا در بورس بزرگ آزمایش کردند. نتایج حاصل نشان دهنده برتری مدل پیشنهادی نسبت به مدل‌های مشابه بود.

ولا و ان جی (۲۰۱۶) پژوهشی در مورد بهبود عملکرد تعديل شده با ریسک معاملات بسامدبالا انجام دادند. آن‌ها قابلیت سیستم‌های فازی مرتبه بالا در کنترل عدم قطعیت معاملات بسامدبالا را بررسی کردند. نتایج پژوهش آن‌ها نشان داد بر اساس معیارهای سودآوری و نسبت شارپ، انفیس نوع دوم پیشنهادی نسبت به انفیس نوع اول و استراتژی خرید نگهداری عملکرد بالاتری داشته است.

باروینک و کرهلیک (۲۰۱۶) داده‌های بسامدبالا و مدل‌های غیرخطی را برای پیش‌بینی نوسان‌پذیری بازار انرژی ترکیب کردند. آن‌ها با به کارگیری چندین سنجه بسامدبالا و مدل‌های مبتنی بر شبکه‌های عصبی مصنوعی به پیش‌بینی چند دوره‌ای نوسان‌پذیری بازار انرژی پرداختند. نتایج نشان داد که مدل پیشنهادی آن‌ها از نظر آماری و اقتصادی عملکرد معناداری داشته است.

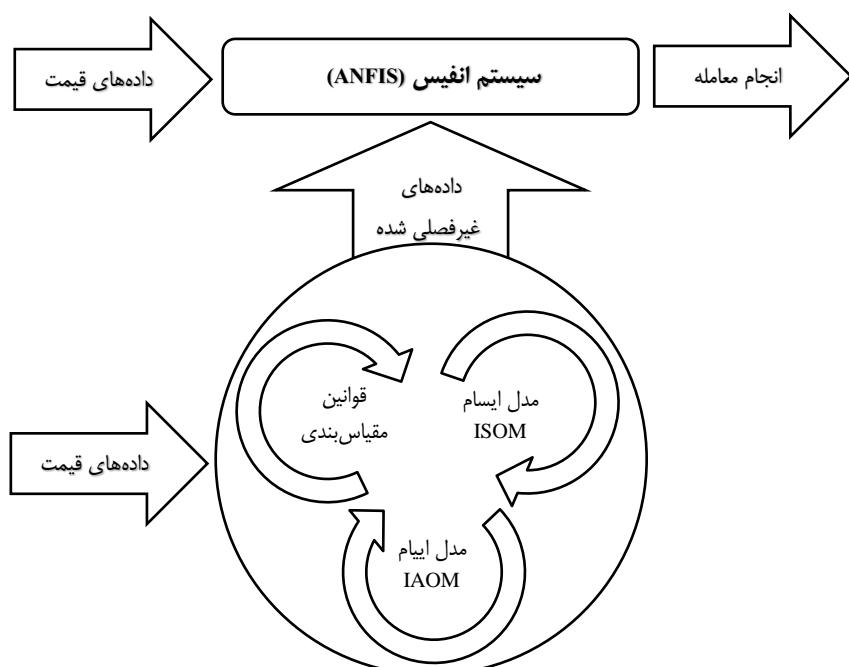
دستپاک و رستگار (۱۳۹۴) با استفاده از داده‌های درون‌روزانه و شاخص‌های تحلیل فنی و با رویکرد معامله‌گر داخلی به پیش‌بینی روند سهم در بورس تهران پرداختند. نتایج پژوهش آن‌ها بیانگر سودآوری سیستم معاملاتی یاد شده بود.

در پژوهش‌های بیان شده، سیستم‌های معاملاتی با داده‌های روزانه بررسی شده‌اند. زیرا به کارگیری داده‌های بسامدبالا منجر به طولانی شدن زمان آموزش مدل‌ها، افزایش زیاد تعداد معاملات و درنتیجه کارمزد معاملات می‌شود، درنتیجه نتایج پژوهش‌ها با چالش مواجه می‌شود. از این‌رو اغلب پژوهش‌های معاملات بسامدبالا بر شاخص‌های برابری ارز تمرکز دارند و توجه به محصولاتی نظیر سکه طلا سابقه چنانی ندارد. در ادامه به جدیدترین پژوهش‌های انجام‌شده در حوزه معاملات بسامدبالا اشاره می‌شود. ویژگی‌های این مقاله طراحی سیستم معاملات بسامدبالا برای پیش‌بینی قیمت سکه طلا با استفاده سیستم نوروفارزی در ایران و استفاده از سنجه‌ای مبتنی بر حدود آستانه‌ای برای اندازه‌گیری نوسان‌پذیری است. در حالی که سیستم‌های معاملاتی

پژوهش‌های انجام شده، بیشتر ماهیت معامله بسامد بالا ندارند و به مسئله نوسان پذیری توجه نمی‌کنند.

روش‌شناسی پژوهش

در این مقاله هوش مصنوعی و مدل‌سازی نوسان پذیری در قالب مدل مشاهده فصلی روزانه و مدل مشاهدات متوسط روزانه ترکیب می‌شود تا چارچوبی کلی حاصل شود که توانایی ایجاد بازده در معاملات بسامد بالا را داشته باشد. شکل ۱، چارچوب کلی سیستم معاملاتی را نمایش می‌دهد.



شکل ۱. چارچوب کلی سیستم معاملاتی (کابلان، ۲۰۰۹)

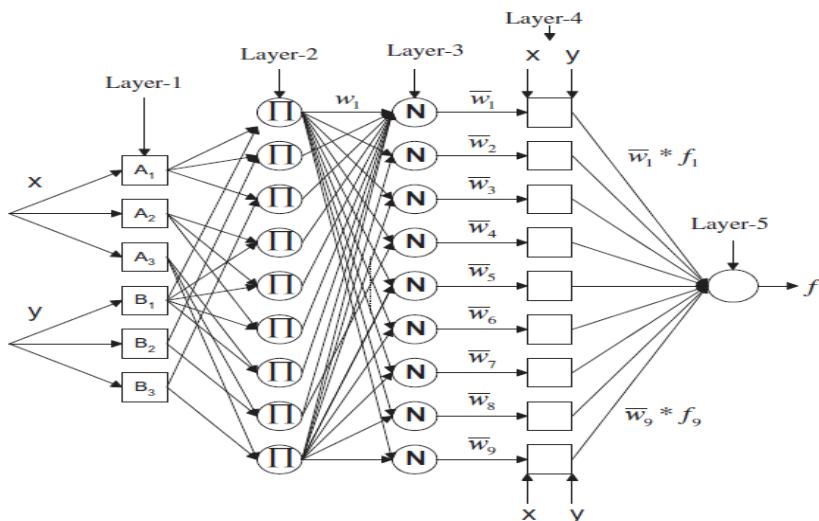
در ادامه بخش‌های مختلف این چارچوب شامل سیستم انفیس، مدل نوسان پذیری، بازتعریف آن، مدل ایسام، مدل ایام و به کارگیری انفیس برای پیش‌بینی مالی و انجام معاملات به ترتیب توضیح داده می‌شود.

سیستم استنتاج فازی مبتنی بر شبکه قطبی (انفیس)

در معماری انفیس از منطق فازی و شبکه‌های عصبی مصنوعی استفاده شده است. انفیس از داده‌های ورودی - خروجی، قوانین اگر - آنگاه فازی و الگوریتم‌های یادگیری شبکه‌های عصبی

مصنوعی برای آموزش استفاده می‌کند. برای ساده‌سازی توصیف ساختار انفیس فرض می‌شود سیستم دارای دو ورودی (X, Y) و یک خروجی است که در حالت کلی به صورت زیر بیان می‌شوند (زانگ، ۱۹۹۳).

اگر x برابر A_1 باشد و Y برابر با B_1 باشد، آنگاه $f = p_1 + q_1 + r$ ، به‌طوری‌که p, q, r پارامترهای خطی خروجی هستند. این معماری با پنج لایه و نه قانون اگر-آنگاه در شکل ۲، نمایش داده شده است.



شکل ۲. ساختار انفیس

هر لایه مسئول اجرای پردازشی خاص بر خروجی لایه قبل است که در ادامه هریک توضیح داده می‌شود.

لایه ۱: در این لایه هر گره از نوع مربعی و همراه با یک تابع گره است، به‌طوری‌که x و y ورودی گره i ام و A_i و B_i برچسب زبانی ورودی‌ها هستند. $O_{1,i}$ تابع عضویت A_i و B_i هستند. به طور معمول $\mu_{A_i(x)}$ و $\mu_{B_i(y)}$ توابعی زنگوله‌ای با حداقل یک و حداقل صفر انتخاب می‌شوند. در این روابط A_i و C_i مجموعه پارامترها هستند. این پارامترها را پارامترهای مفروض نیز می‌نامند.

$$\begin{aligned} O_{1,i} &= \mu_A(x), \text{for } i = 1, 2, 3 \\ O_{1,i} &= \mu_{B_{i-3}}(y), \text{for } i = 4, 5, 6 \end{aligned} \quad \text{رابطه ۱}$$

لایه ۲: هر گره در این لایه، از نوع دایره‌ای است. این گره سیگنال‌های ورودی را در یکدیگر ضرب می‌کند و با نماد \prod نمایش داده می‌شود.

$$O_{2,i} = w_i = \mu_{Ai}(x) \cdot \mu_{Bi-3}(y), i = 1, 2, 3, \dots, 9 \quad \text{رابطه ۲}$$

لایه ۳: گره‌های موجود در این لایه از نوع دایره‌ای هستند و با نماد N نمایش داده می‌شوند.

گردها ام نسبت قدرت عمل^۱ قانون i ام را به مجموع قدرت عمل تمام قوانین نشان می‌دهد.

$$O_{3,i} = \bar{w}_i = w_i / (w_1 + w_2 + \dots + w_9), i = 1, 2, 3, \dots, 9 \quad \text{رابطه ۳}$$

لایه ۴: گره‌های موجود در این لایه از نوع مربعی هستند و با یک تابع گره همراه شده‌اند.

$$O_{4,i} = \bar{w}_i \cdot f_i = w_i \cdot (p_i x + q_i y + \dots + r_i), i = 1, 2, 3, \dots, 9 \quad \text{رابطه ۴}$$

W_i نشان‌دهنده خروجی لایه سوم و {p_i, q_i, r_i} مجموعه پارامترها هستند. پارامترهای این

لایه پارامترهای ثابت خواهند بود.

لایه ۵: در این لایه تنها یک گره از نوع دایره‌ای وجود دارد که خروجی کلی را به صورت

مجموع تمام سیگنال‌های ورودی محاسبه می‌کند و با علامت \sum نمایش داده می‌شود.

$$O_{5,i} = \text{overall output} = \sum_i \bar{w}_i \cdot f_i = \frac{\sum_i w_i \cdot f_i}{\sum_i w_i} \quad \text{رابطه ۵}$$

مدل‌سازی نوسان‌پذیری

از آنجا که ممکن است ورودی‌های انفیس نامناسب باشند، نتایج حاصل از آن نیز ممکن است مغلوظ شوند. برای فائق آمدن بر این مسئله تلاش می‌شود داده‌ها به گونه‌ای تعییل شوند تا الگوهای فصلی و تأثیرات نوسان‌پذیری در آن‌ها حذف شوند. برای حذف تأثیرات نوسان‌پذیری ابتدا لازم است سنجه‌ای مناسب برای شناسایی و اندازه‌گیری نوسان‌پذیری تعریف شود. بر اساس پژوهش هال (۱۹۹۸) با محاسبه انحراف استاندارد درصد تغییرات قیمت در دوره ۲۴ ساعته می‌توان این مفهوم را اندازه‌گیری کرد، از این‌رو برای محاسبه نوسان‌پذیری می‌توان از رابطه ۶ استفاده کرد.

$$S_i = \ln\left(\frac{u_i}{u_{i-1}}\right) \quad \text{رابطه ۶}$$

انحراف معیار_i به صورت رابطه ۷، محاسبه شده است.

$$U = \sqrt{\frac{u_i}{u_{i-1}} \sum_{i=1}^n (s_i - \bar{s})^2} \quad \text{رابطه ۷}$$

باز تعریف نوسان پذیری

با توجه به این که در مقاله حاضر از داده‌های بسامد بالا استفاده می‌شود و بر اساس مرور پیشینهٔ پژوهش هزینه‌های معاملاتی می‌تواند منجر به زیان‌آوری سیستم‌های معاملاتی شود، نوسان پذیری به صورت دیگری تعریف و استفاده می‌شود. بدین صورت که ابتدا هر تغییری به سمت بالا یا پایین، با یک حد آستانه‌ای از پیش تعریف شده مقایسه می‌شود، زمان و قیمت‌های نسبی نیز مشخص شده و تمام داده‌ها به صورت مرحله‌ای در انبارهای زمانی ذخیره می‌شوند. نحوه انجام این امور در قالب مدل‌های ایسام و ایام در زیربخش‌های بعدی توضیح داده می‌شود. تحلیل نتایج مدل‌ها نیز پس از آن انجام می‌شود.

مدل مشاهده فصلی روزانه (ISOM)

مدل مشاهده فصلی روزانه (ایسام) به طور ساده مدلی است که تعدادی حد آستانه را در نظر می‌گیرد و زمان بروز تغییرات جهت را مشاهده می‌کند. این مدل مجموعه داده‌ها را به صورت مرحله‌ای و به طور متوالی تفسیر می‌کند و مشاهدات را در انبارهای زمانی^۱ ذخیره می‌کند. این کار درنهایت، افق زمانی بروز مشاهدات مهم را به طور دقیق نشان می‌دهد، درنتیجه در صورت صحیح بودن مقیاس‌بندی، صرف‌نظر از حدود آستانه‌ای در نظر گرفته شده، الگوهای تأثیرات فصلی مشابه خواهند بود. انبارهای زمانی می‌توانند بر اساس بسامد دلخواه، تغییر کنند. به عبارت دیگر از انواع و اقسام چارچوب‌های زمانی می‌توان استفاده کرد. تعریف ریاضی ایسام در ادامه بیان می‌شود.

ایسام، در یک‌زمان مشخص و با یک حد آستانه‌ای مشخص، برابر با تعداد رخدادهایی است که در آن بازه زمانی در مجموعه داده‌ها رخداده است، که در رابطه ۸، نشان داده می‌شود.

$$ISOM_{t|dx(\%)} = \sum_{i=1}^n N(dc)_i \quad (8)$$

به طوری که t زمان، $(\%)$ حد آستانه، n کل تعداد روزها در مجموعه داده‌ها و $N(dc)$ تعداد تغییرات جهت (رخدادها) است (کابلان، a2۰۰۹).

مدل مشاهدات متوسط روزانه (IAOM)

برای تخمین نوسان پذیری متوسط روزانه و جداسازی الگوهای فصلی مدل ایسام از مدل ایام استفاده می‌شود (باونز، اومرین و گیوت، ۲۰۰۵). این مدل به صورت رابطه ۹ تعریف می‌شود.

1. Time Bins

$$IAOM_{t|dx(\%)} = \frac{1}{M} \sum_{i=1}^M N(dc)_i \quad (9)$$

به طوری که t زمان، $(\%)$ حد آستانه‌ای، M کل تعداد روزها در مجموعه داده‌ها و $N(dc)$ تعداد تغییرات جهت (رخدادها) است.

به کارگیری انفیس برای پیش‌بینی مالی

مدل پیشنهادی این مقاله از ساختار فوق استفاده می‌کند و داده‌های سری زمانی بسامد بالا را به عنوان ورودی به کار می‌گیرد، بنابراین ورودی این داده‌ها، از نوع سری زمانی قیمت هستند. مراحل کار به این صورت است که ابتدا 500 داده برای آموزش و تولید سیستم استنتاج فازی اولیه و 500 داده برای آزمایش در نظر گرفته می‌شوند. این کار، سبب تغییر پارامترها و توابع عضویت^۱ انفیس می‌شود. سپس انفیس قادر خواهد بود تا دستهٔ بعدی داده‌ها را دریافت کند و بر اساس الگوی شناسایی شده پیش‌بینی‌هایی برای دستهٔ جدید داده‌ها، ارائه کند.

قبل از آموزش سیستم‌های معاملاتی شامل انفیس و بهینه سازی آن، ضروری است نحوه تعریف ورودی و خروجی‌های سیستم تعریف شوند. روش استاندارد، تعریف نگاشتی تأخیری از سری‌های زمانی به صورت رابطهٔ 10 ، است.

$$(x(t - (\tau - 1)\Delta), \dots, x(t - \Delta), x(t) \rightarrow x(t + s)) \quad (10)$$

نگاشت استفاده شده در این مقاله شامل سه متغیر تأخیری قیمت به همراه قیمت فعلی است.

مقدار حاصله به صورت شاخص جنبش^۲ در پیش‌بینی استفاده می‌شود، از این‌رو مقدار $\tau = 4$ برابر $\Delta = 1$ خواهد بود. پنج تایی‌های مرتب ورودی-خروجی به صورت رابطهٔ 11 ، هستند.

$$(x(t - 3), x(t - 2), x(t - 1), x(t), x(t + 1)) \quad (11)$$

این روش تغذیه سیستم، برای داده‌های آموزش و آزمایشی روزانه به کار می‌رود. سیستم حاصله پیش‌بینی‌هایی از تغییرات آتی بازار ارائه خواهد کرد. در این مقاله ابتدا سیستم انفیس به صورت یک سیستم معاملاتی در نظر گرفته می‌شود و در ادامه از آن با عنوان سیستم انفیس نام برده می‌شود. به عبارت دیگر خروجی انفیس که توسط داده‌های آموزشی، آموزش داده شده است، سیستم معاملاتی انفیس را تشکیل میدهد.

۱. توابع عضویت برای فازی‌سازی متغیرهای کمی در سیستم فازی استفاده می‌شود. این توابع میزان تعلق اعضاء به مجموعه را بیان می‌کنند.

2. Movement Index

۸۹ سیستم استنتاج نوروفازی برای معاملات بسامدبالا با استفاده از...

استراتژی معاملاتی بدین صورت تعریف می‌شود که در صورت صعودی بودن پیش‌بینی قیمت توسط سیستم‌های معاملاتی، سیگنال خرید صادر شده و در صورت نزولی بودن پیش‌بینی، سیگنال فروش صادر می‌شود.

به دلیل وجود هزینه معاملات در دنیای واقعی یک ماشه معاملاتی نیز تعریف و استفاده می‌شود. درنتیجه فقط زمانی سیگنال معتبر تلقی خواهد شد که مقدار پیش‌بینی از ماشه خرید بیشتر باشد. برای حالت فروش نیز عکس این حالت برقرار تعریف می‌شود. این سیستم معاملاتی، با داده‌های بسامدبالا آزموده می‌شود. علاوه بر این داده‌های قیمت سهام نیز برای آزمایش سیستم معاملاتی استفاده می‌شود تا کارایی پیش‌بینی‌ها با داده‌های غیر بسامدبالا نیز بررسی شود.

کارایی اولیه و تحلیل

برای بررسی عملکرد سیستم‌های معاملاتی از معیارهای گوناگونی استفاده می‌شود (آتسالیکیس و والاونیس، ۲۰۰۹؛ داش و داش، ۲۰۱۶؛ ولا و لا و ان جی، ۲۰۱۶). در این مقاله نیز مشابه پژوهش‌های اشاره شده از معیارهای زیر استفاده شده است.

فرخ بازده سرمایه‌گذاری

نرخ بازده سرمایه‌گذاری شاخصی است که کارایی سرمایه‌گذاری را محاسبه می‌کند. این شاخص نسبت سود یا زیان حاصل از سرمایه‌گذاری در برابر میزان هزینه سرمایه‌گذاری شده را محاسبه می‌کند و به صورت رابطه ۱۲، محاسبه می‌شود.

$$ROI = \ln \frac{v_f}{v_i} \quad (12)$$

به طوری که v_f بیانگر سرمایه‌گذاری اولیه است و v_i بیانگر سرمایه نهایی است. به دلیل انعطاف‌پذیری و سادگی ROI شاخصی محبوب است.

نسبت شارپ

نسبت شارپ برای محاسبه بازده تعديل شده با ریسک یک دارایی سرمایه‌ای یا پرتفوی استفاده می‌شود. به عبارت دیگر این شاخص به سرمایه‌گذاران می‌گوید میزان بازدهی دارایی یا پرتفوی یک استراتژی معاملاتی، هوشمندانه است یا دارای ریسک اضافی است. این نسبت به صورت رابطه ۱۳، تعریف می‌شود.

$$Sharp Ratio = \frac{R_i - R_f}{\sigma_p} \quad (13)$$

به طوری که R_p بازده مورد انتظار، R_f بازده بدون ریسک و σ_p انحراف معیار پرتفوی است. سرمایه‌گذاران اغلب سرمایه‌گذاری‌هایی را انتخاب می‌کنند که نسبت شارپ بالاتری دارند زیرا نسبت شارپ بالاتر به معنی عملکرد تعدلشده با ریسک بالاتر است.

نرخ موفقیت

نرخ موفقیت از تقسیم تعداد پیش‌بینی‌های صحیح به کل پیش‌بینی‌ها به دست می‌آید. این نسبت توصیف کلی و قابل تفسیر از عملکرد مدل‌ها ارائه می‌دهد. هر چه مقدار نرخ موفقیت بیشتر باشد، پیش‌بینی‌های بهتری انجام شده است.

داده‌ها

در این پژوهش از داده‌های قیمت سکه در بازه زمانی ۲۶ خرداد ۱۳۹۳ تا ۱۳ اردیبهشت ۱۳۹۵ استفاده شد. همچنین چارچوب زمانی داده‌های این پژوهش ۵ دقیقه‌ای است. سری زمانی استفاده شده از سامانه‌های معاملاتی شرکت‌های بورسی و نرم‌افزار ره‌آوردنوین به دست آمده است. آمار توصیفی داده‌ها شامل میانگین، میانه، ضریب چولگی، ضریب کشیدگی آزمون جارک‌برا در جدول ۱، ارائه شده است. توزیع سری زمانی پژوهش نرمال نیست.

جدول ۱. آمار توصیفی داده‌های پژوهش

سری زمانی قیمت سکه	میانگین	میانه	ضریب معیار	انحراف معیار	ضریب چولگی	ضریب کشیدگی	آزمون جارک‌برا
۹۴۶۳۲۰۰	۹۴۲۵۰۰۰	۳۸۷۱۱۰	۰/۳۹۶	۳/۰۸۲۰	۲۶۴/۲۱۵۱		

مجموعه داده‌ها به ۱۰ زیرمجموعه ۱۰۰۰ تایی تقسیم شد. در هر زیرمجموعه، ۵۰۰ داده اول برای آموزش سیستم استفاده شد و ۵۰۰ داده بعدی برای بررسی عملکرد سیستم و به روزرسانی ساختار شبکه با استفاده از خطای استفاده شد. سپس زیرمجموعه بعدی داده‌ها به سیستم ارائه شد. از آنجا که هر مجموعه پوشش مناسبی از فضای است، مسئله خودهمبستگی رفع می‌شود (کابلان، ۲۰۰۹).

نتایج شبیه‌سازی با استفاده از روش شناسی و معماری توضیح داده شده در بخش بعدی مقاله ارائه می‌شود.

یافته‌های پژوهش

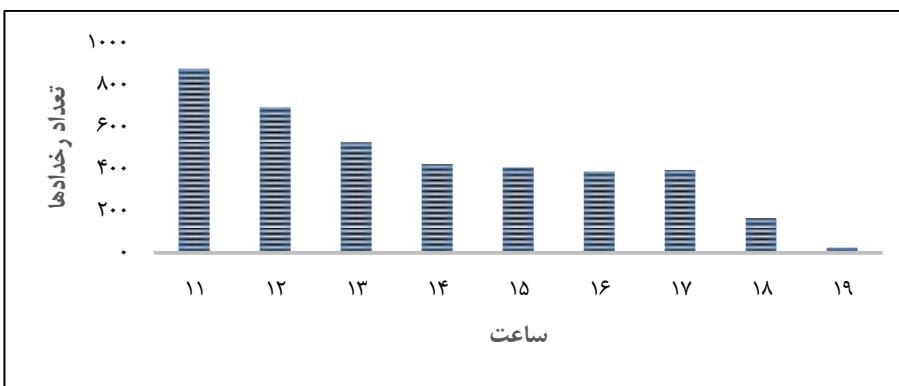
نتایج عملکرد سیستم انفیس در جدول ۲، با استراتژی رایج خرید و نگهداری مقایسه شده است. نسبت شارپ مثبت نشان می‌دهد که سیستم برای دستیابی به بازدهی، ریسک زیادی را تحمل نشده است. همچنین نرخ بازده سرمایه‌گذاری ۲۲ درصد است که مقداری زیاد و مناسب برای سرمایه‌گذاری حدوداً دو ساله است. نرخ موفقیت نیز نشان می‌دهد که صحت پیش‌بینی‌های سیستم بالا است.

جدول ۲. عملکرد انفیس در مقایسه با استراتژی خرید و نگهداری

نسبت شارپ	نرخ بازده سرمایه‌گذاری	نرخ موفقیت	استراتژی خرید و نگهداری
.۰/۰۱	.۰/۶	.۰/۳۱	سیستم انفیس
.۰/۱۶	.۰/۲۲	.۰/۶۲	

از آنجا که پالایش داده‌ها ممکن است به فرایند یادگیری و عملکرد سیستم کمک کند در ادامه نتایج مدل‌های ایسام و اییام و ترکیب آن‌ها با انفیس برای پالایش ورودی‌ها و نتایج بهتر ارائه می‌شود.

مدل ایسام را می‌توان به صورت سنجه نوسان‌پذیری در نظر گرفت، چون نگاشتی از زمان به نوسان‌پذیری با دیدگاه مبتنی بر رخداد است. داده‌ها در چارچوب زمانی^۱ یک ساعته نیز بررسی می‌شوند از این‌رو ۹ انبار زمانی به دست آمد. هر انبار زمانی بیانگر یکی از ساعت‌انجام معاملات است. نتایج حاصل از ایسام در این بازه‌های زمانی به صورت شکل ۳، ارائه شده است.

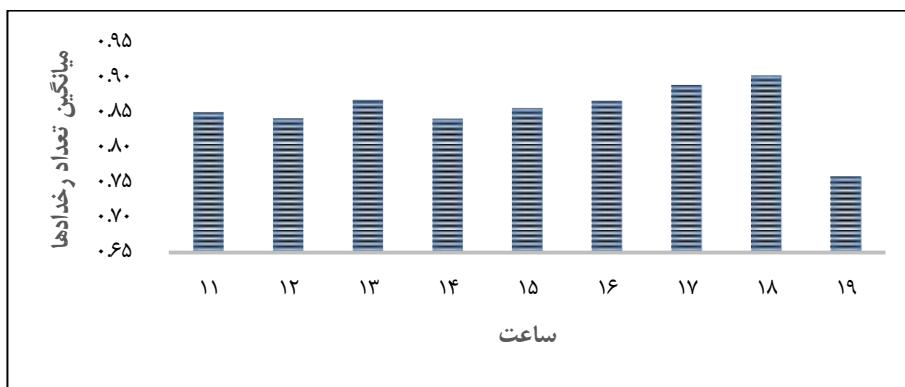


شکل ۳. نتایج مدل ایسام در چارچوب زمانی یک ساعته

1. Timeframe

تحلیل شکل ۳، به این صورت است که بیشتر فعالیت‌ها یا رخدادها بین ساعت ۱۱ و ۱۲ رخ می‌دهند که همان ساعت شروع بازار و بروز واکنش‌ها است. در ساعت ۱۹ کمترین نوسانات بروز کرده البته به دلیل کم بودن تعداد داده‌ها قابل استناد نیست. میانگین نوسانات به مقدار داده‌ها نشان می‌دهد این زمان از روز نیز حائز اهمیت است.

به نظر می‌رسد میانگین نتایج بالا نیز باید محاسبه و ارائه شود تا میزان نوسان پذیری روزانه، مدل استاندارد و زمان‌های دارای بیشترین یا کمترین نوسان پذیری متوسط روزانه مشخص شود. مدل مشاهدات متوسط روزانه (IAOM) به این امر می‌پردازد. ایده کلی مدل ایام آن است که متوسط تعداد مشاهدات در نمونه را در نظر می‌گیریم تا مدلی به دست آید که متوسط تعداد رخدادها در روز را ارائه کند. این مدل به طور کلی متوسط مدل ایسام است که نشان می‌دهد یک روز به طور میانگین چگونه خواهد بود. نتیجه مدل ایام با چارچوب زمانی ساعتی در شکل ۴، ارائه می‌شود.



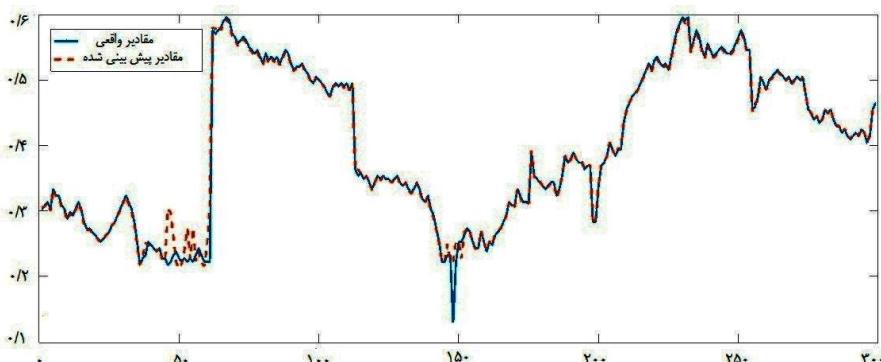
شکل ۴. نتایج مدل ایام در چارچوب زمانی یک ساعته

شکل ۴، درواقع احتمال بروز رخداد در ساعت مختلف روز را در بازه زمانی پژوهش نشان می‌دهد. تحلیل نتایج این نمودار، نتایج حاصل از مدل ایسام را تأیید می‌کند چون بیشترین نوسانات طی ساعت ۱۱ تا ۱۲ رخ می‌دهد. ساعت ۱۸ تا ۱۹ تأثیر ناچیزی بر نوسان پذیری دارند، بنابراین هنگام تغذیه به انفیس می‌توان آن‌ها را حذف کرد.

بینه‌سازی انفیس با ایسام

در بخش قبل ملاحظه شد که انفیس، سیستمی با عملکرد مناسب برای پیش‌بینی و معامله با داده‌های با سامدبالا است. در این زیر بخش، مدل مشاهدات فصلی روزانه را برای پالایش و

پاکسازی داده‌ها استفاده می‌کنیم. چارچوب زمانی در این بخش نیز درون-روزانه است. در شکل ۵، نتیجهٔ پیش‌بینی حاصل از مدل انفیس با مقادیر واقعی قیمت‌ها ارائه شده است. مقایسه مقادیر نشان می‌دهد که سیستم معاملاتی قادر به رهگیری تغییرات بازار به طور مناسب است.



شکل ۵. مقایسه نتایج مدل انفیس و داده‌های واقعی

ابتداء، مدل ایسام بازطراحی می‌شود تا داده‌های ۵ دقیقه‌ای را به جای داده‌های ۳۰ دقیقه‌ای یا یک ساعته دریافت کند. بدین ترتیب انبارهای زمانی ۵ دقیقه‌ای به دست می‌آید. با افزایش تعداد رخدادها و تعداد زمان‌هایی که قیمت از حد آستانهای فراتر می‌رود، شمارنده رخدادها نیز افزایش می‌یابد. انفیس ورودی‌هایی را دریافت می‌کند که دارای تعداد مشاهدات بیش از سه رخداد است، یعنی انفیس با داده‌های دارای نوسان پذیری زیاد آموزش داده می‌شود. جدول ۳، نتایج آموزش جدید انفیس با داده‌های غیر فصلی شده با مدل‌های ایسام و ایام را نمایش می‌دهد. نتایج این مدل با استراتژی خرید و نگهداری سنتی مقایسه شده است.

جدول ۳. مقایسه نتایج انفیس تغذیه شده با مدل ایسام

نسبت شارپ	نرخ بازده سرمایه‌گذاری	نرخ موفقیت	
.۰/۱	.۰/۶	.۰/۳۱	استراتژی خرید و نگهداری
.۰/۱۶	.۰/۲۲	.۰/۶۲	سیستم نوروفازی
.۰/۱۹	.۰/۳۷	.۰/۶۹	سیستم نوروفازی با به کار گیری ایسام

نتایج این جدول در مقایسه با نتایج جدول یک، بر اساس معیارهای نرخ بازده، نسبت شارپ و نرخ موفقیت، بهبود چشمگیری یافته‌اند. این یافته‌ها نشان می‌دهند که داده‌های شفاف‌تر منجر

به بهبود عملکرد انفیس می‌شود. به عبارت دیگر در صورتی که انفیس با حجم زیادی از داده‌های آموزشی (بیش از یک سال) تغذیه شود و سیستم مدل‌سازی نوسان‌پذیری مناسبی برای پالایش کردن به کار رود، عملکرد سیستم به طور معنی‌داری بهبود می‌یابد.

نتیجه‌گیری و پیشنهادها

در این مقاله حوزه‌های گوناگونی از مالی محاسباتی بررسی شد. از شاخه‌های علمی محاسبات نرم و هوش مصنوعی برای توسعه سیستم استنتاج نورووفازی انفیس و از مدل مشاهده فصلی روزانه برای کنترل نوسان‌پذیری استفاده شد. با ترکیب سیستم انفیس و این مدل، سیستم معاملاتی برای انجام معاملات بسامد بالا ارائه شد.

نرخ موفقیت سیستم نورووفازی به تنها بیان برای ۶۲ درصد بوده است. بیشتر بودن این شاخص از ۵۰ نشان‌دهنده موفقیت سیستم معاملاتی است. همچنین پس از کنترل نوسان‌پذیری با استفاده از مدل ایسام نرخ موفقیت سیستم معاملاتی به ۶۹ درصد رسید که نشان‌گر برتری سیستم معاملاتی نسبت به استراتژی خرید و نگهداری و سیستم نورووفازی انفیس است. نتایج حاصل از این پژوهش با نتایج پژوهش‌های آتسالیکیس و والاوانیس (۲۰۰۶)، ژانگ و همکاران (۲۰۱۵) و گرلین و مک‌گلیتی، بالاتریچی و کالمون (۲۰۱۶) منطبق است. نرخ موفقیت در این پژوهش‌ها به ترتیب برابر با ۶۰ درصد، ۵۷/۳۸ درصد و ۴۹/۷۶ درصد است. بیشتر بودن نرخ موفقیت در این پژوهش را می‌توان به توجه به عامل زمان در مدل‌های ایسام نسبت داد.

نتایج به دست آمده مشوقی برای انجام پژوهش‌های آتی در این حوزه است. امکان به کارگیری هر حد آستانه‌های و هر چارچوب زمانی از ویژگی‌های اساسی سیستم معاملاتی پیشنهادی است، بنابراین در پژوهش‌های آتی می‌توان کارایی این سیستم را در محصولات زمانی متفاوت و در چارچوب‌های زمانی دیگر بررسی کرد. محدودیت پردازشی سیستم‌های رایانه‌ای با توجه به حجم عظیم داده‌ها از جمله محدودیت‌های پژوهشی در حوزه معاملات بسامد بالا است. امید است با توجه به مجاز شدن معاملات الگوریتمی در کشور و توسعه سورهای مجازی پژوهش‌های بیشتری در این حوزه انجام شود.

منابع

- دستپاک، م.، و رستگار، م. (۱۳۹۴). ارائه مدل معاملاتی با تکرار بالا در بورس اوراق بهادار تهران. فصلنامه علمی پژوهشی دانش سرمایه‌گذاری، ۱۵(۴)، ۸۹-۱۰۹.

References

- Araújo, R., Oliveira, a., & Meira, S. (2015). A Hybrid Model for High-frequency Stock Market Forecasting. *Expert Systems with Applications*, 42 (8), 4081–4096.
- Atsalakis, G., & Valavanis, K. (2006). A Neuro-fuzzy Controller for Stock Market Forecasting. Working Paper, Technical University of Crete.
- Atsalakis, G., & Valavanis, K. (2009). Forecasting Stock Market Short-term Trends using a Neuro-fuzzy Based Methodology. *Expert Systems with Applications*, 36(7), 10696–10707.
- Baruník, J. Krehlík, T. (2016). Combining High Frequency Data with Non-linear Models for Forecasting Energy Market Volatility. *Expert Systems with Applications*, 55(1), 222–242.
- Bauwens, C., Ben Omrane, L., & Giot, W. P. (2005). News Announcements, Market Activity and Volatility in the Euro/Dollar Foreign Exchange Market. *Journal of International Money and Finance*, 24(7), 1108—1125.
- Brogaard, J., Hendershott, T., & Riordan, R. (2014). High-frequency Trading and price discovery. *Review of Financial Studies*, 27(8), 2267–2306.
- Chen, S., Ying, L., & Pan., M. (2010). Forecasting Tourist Arrivals by using the Adaptive Network-based Fuzzy Inference System. *Expert Systems with Applications*, 37(2), 1185–1191.
- Dastpk, M., Rastgar, M. (2014). Presenting of High-Frequency Trading System, *Investment Knowledge*, 4(15), 89-109. (In Persian)
- Dash, R. Dash, P. (2016). A Hybrid Stock Trading Framework Integrating Technical Analysis with Machine Learning Techniques. *The Journal of Finance and Data Science*, 2(1), 42-57.
- Dempster, M., Payne, T., Romahi, Y., & Thompson, G. (2001) Computational Learning Techniques for Intraday FX Trading using Popular Technical Indicators. *IEEE Transactions on Neural Networks*, 12(4), 744-754.
- Dracogna, M., Gencay, R. U., Muller, U., & Olsen, R. (2001). An Introduction to High-Frequency Finance, Academic Press.

- Gerlein, E. A., McGinnity, M., Belatreche, A., & Coleman, S. (2016). Evaluating Machine Learning Classification for Financial Trading: An Empirical Approach. *Expert Systems with Applications*, 54(1), 193-207.
- Hull, J. (1998). Incorporating Volatility Updating into the Historical Simulation Method for VaR. *Journal of Risk*, 1(1), 19-25.
- Jang, R. (1993). ANFIS: Adaptive Network-based Fuzzy Inference System, *IEEE Transactions on Systems, Man and Cybernetics*, 23(3), 665-685.
- Kablan, A. (2009a). Adaptive Neuro Fuzzy Inference Systems for High Frequency Financial Trading and Forecasting. *Proceedings of the Third International Conference on Advanced Engineering Computing and Applications in Sciences*.
- Kablan, A. (2009b). Adaptive Neuro-Fuzzy Inference System for Financial Trading using Intraday Seasonality Observation Model. *International Journal of Social, Behavioral, Educational, Economic, Business and Industrial Engineering*, 3(10), 1909-1918.
- Kearns, M., Kulesza, A., & Nevmyvaka, Y. (2010). Empirical Limitations on High-frequency Trading Profitability. *Journal of Trading*, 5(4), 50–62.
- Melin, M., Soto, P., Castillo, J. O., & Soria, J. (2012). A New Approach for Time Series Prediction using Ensembles of ANFIS Models. *Expert Systems with Applications*, 3(39), 3494–3506.
- Murphy, J. (1988). *Technical Analysis of Futures Markets*. New York, N.Y.: New York Inst. of Finance.
- Rechenthin, M., & Street, W. N. (2013). Using Conditional Probability to Identify Trends in Intra-day High-frequency Equity Pricing. *Physica A: Statistical Mechanics and its Applications*, 392(24), 6169–6188.
- Sahin, S., Tolun, M., R., Hassanzadeh, R. (2012). Hybrid Expert Systems: A Survey of Current Approaches and Applications. *Expert Systems with Applications*, 39(4), 4609–4617.
- Schulmeister, S. (2009). Profitability of Technical Stock Trading: Has it moved from Daily to Intraday Data? *Review of Financial Economics*, 18(4), 190–201.

- Tsang, E. (2009). Forecasting - Where Computational Intelligence Meets the Stock Market. *Frontiers of Computer Science in China*, 1(3), 53–63.
- Vella, V., & Lon, N. W. (2016). Improving Risk-adjusted Performance in High Frequency Trading using Interval Type-2 Fuzzy Logic. *Expert Systems with Applications*, 55(1), 70–86.
- Vella, V. (2016). Improving risk-adjusted performance in high-frequency trading: the role of fuzzy logic systems. P.hd. Dissertation. Centre for Computational Finance and Economic Agents (CCFEA), University of Essex.
- Wei, L.-Y., Cheng, C.-H., & Wu, H.-H. (2014). A Hybrid Anfis Based on N-period Moving Average Model to Forecast TAIEX Stock. *Applied Soft Computing*, 19(1), 86–92.
- Zadeh, L. (1975). The Concept of a linguistic Variable and its Application to Approximate Reasoning – Part I. *Information Sciences*, 8(3), 199–249.
- Zankova, E. (2016). High Frequency Financial Time Series Prediction: Machine Learning Approach. M.sc. Dissertation. Faculty of Science and Technology UiT the Arctic University of Norway.
- Zhang, X., Hu, Y., Xie, K., Zhang, W., Su, L., & Liu, M. (2015). An Evolutionary Trend Reversion Model for Stock Trading Rule Discovery. *Knowledge-Based Systems*. 79(1), 27–35.