فصلنامه رویکردهای نوین در مهندسی صنایع و مدیریت
سال سوم، شماره ۴، زمستان ۱۴۰۴
www.iem-science.ir

پوشش ریسک با رگرسیون های خطی و شبکه های عصبی

فاطمه قنبرزاده عنبرانی
کارشناسی ارشد ریاضی مالی، دانشگاه تربیت مدرس، تهران، ایران
Fateme.gnz@gmail.com

چکیده

در این پژوهش، شبکه‌های عصبی را به عنوان ابزارهای تخمین غیرپارامتری برای پوشش‌ریسک اختیارهای معامله بررسی می‌شود. بدین منظور، شبکه ای با نام هجنت(HEDGENET) طراحی شده که خروجی آن، یک استراتژی پوشش‌ریسک است. این شبکه، به منظور حداقل کردن خطای پوشش‌ریسک به جای خطای قیمت‌گذاری، آموزش داده می شود. این شبکه که در مورد مهلت زمان و قیمت‌های لحظه ای شاخص های اختیارمعامله یورو استاکس ۵۰ و اس اندپی ۵۰۰ اعمال شده است، قابلیت کاهش معنادار خطای میانگین مربعات پوشش‌ریسک معیار بلک شولز را دارد. با این حال، می توان به مزیت مشابه از طریق رگرسیون های خطی ساده با احتساب اثر اهرم (لوریج) دست یافت.

واژگان کلیدی: الگوگیری؛ بلک شولز؛ خطای پوشش ریسک؛ نشت اطلاعات؛ اثر اهرم؛ پوشش ریسک آماری

[Downloaded from www.iem-science.ir on 2026-11-08]

۱. مقدمه

شبکه‌های عصبی مصنوعی (ANN) به عنوان یک ابزار غیر پارامتری برای مدیریت ریسک اختیارمعامله، پیشنهاد شدند. در ادامه نشان می دهیم که برای تخمین نسبت پوشش‌ریسک بهینه، شبکه‌های عصبی مصنوعی برتری چندانی نسبت به رگرسیون های خطی که صرفا از درجات حساسیت اختیار معامله استاندارد استفاده می کنند، ندارند.

ما به بررسی کاربرد مدیریت ریسک مدون و کاملا مشخص شامل کاهش واریانس خطای پوشش‌ریسک در معامله اختیارمعاملات روزانه می پردازیم. به طور دقیق تر، ما یک مدل یک دوره ای را در نظر گرفته و فرض می کنیم که یک عامل در حال معامله شورت (فروش) بر روی اختیارمعامله (یا بخش کراس اختیار معاملات) است. بر اساس قرارداد حسابداری تعدیل حساب ها، کنترل مناسب خطای پوشش ریسک برای دوره های زمانی کوتاه حتی با احتساب اختیارمعاملات دارای مهلت طولانی ضروری است. اپراتور به منظور کاهش واریانس سبد سهام، می تواند اختیار اصلی را خریداری کرده یا بفروشد. امروز او اختیارمعامله را با قیمت $C_{.}$ می فروشد. او هم اکنون می تواند δ سهم شاخص اصلی را با قیمت $S_{.}$ و $C_{.} - \delta S_{.}$ واحد دارایی بدون ریسک را بخرد. همچنین ارزش سبدسهام امروز مساوی $V_{.} = ۰$ است. ارزش سبد کنونی او عبارتست از:

$$V_{۱}^{\delta}=\delta S_{۱}+(۱+r_{onr}\Delta t)(C_{.}-\delta S_{.})-C_{۱} \qquad (۱)$$

که $S_{۱}$ و $C_{۱}$ نشان دهنده قیمت های فردای شاخص اصلی و اختیارمعامله، r_{onr} نرخ یک شبه ای است که عامل می تواند پول را قرض گرفته و قرض بدهد و $\Delta t = ۱/۲۵۳$ است. هدف عامل، انتخاب δ به نحوی است که واریانس ارزش ثروت فردا $var[V_{۱}^{\delta}]$حداقل شود.

در ادامه، از آنجایی که مقدار Δt ناچیز است، می توانیم واریانس را با میانگین مربعات مورد انتظار، تقریب بزنیم. در واقع اگر بازده مورد انتظار پر ریسک برابر با بازده بدون ریسک باشد، مقدار مورد انتظار $E[V_{۱}^{\delta}]$ به طور کلی وابسته به δ نیست. در واقع، هدف عامل حداقل کردن خطای میانگین مربعات پوشش ریسک (MSHE) است.

$$E\left[\left(V_{۱}^{\delta}\right)^{۲}\right]=E[(\delta S_{۱}+(۱+r_{onr}\Delta t)(C_{.}-\delta S_{.})-C_{۱})^{۲}] \qquad (۲)$$

حال فرض می کنیم که اختیارمعامله،اختیارمعامله خرید (call) اروپایی است. سپس گزینه ساده و استاندارد، استفاده از معیار دلتای بلک شولز حسابرس است (دلتا بلک شولز)

$$\delta_{BS}=N(d_{۱}) \qquad (۳)$$

که N نشان دهنده تابع توزیع نرمال تجمعی است و

$$d_{۱}=\frac{۱}{\sigma_{impl}\sqrt{\tau}}\left[\ln\left(\frac{S_{.}}{K}\right)+\left(r+\frac{۱}{۲}\sigma_{impl}^{۲}\right)\tau\right] \qquad (۴)$$

در این رابطه τ، زمان مشخص بر حسب نسبت سالانه، σ_{impl} نوسان ضمنی سالانه اختیارمعامله، K قیمت اعمال و r نرخ بهره بدون ریسک متناظر با سررسید اختیارمعامله است. عامل در پی انتخاب $\delta = \delta_{BS}$ است؛ اگر اختیارمعامله به صورت فروش(put) باشد، در این صورت او بر اساس برابری خرید- فروش، $\delta = \delta_{BS} - ۱$ را انتخاب می کند. از آنجایی که نرخ بهره r قابل اغماض است، اما فرض می کنیم که این پارامتر، صفر است. سپس می توان دلتا بلک شولز را به صورت تابعی از دو متغیر شامل وضعیت مالی $M=S_{.}/K$ و ریشه مجذور کل واریانس ضمنی $\sigma_{impl}\sqrt{\tau}$ نوشت. در این صورت، می توان به رابطه زیر دست یافت.

[Downloaded from www.iem-science.ir on 2026-11-08]

$$\delta_{BS}=f_{BS}(M,\sigma_{impl}\sqrt{\tau}) \quad (۵)$$

حال می توان کارکرد های شاخص های دیگر را مطالعه کرد. ما f_{BS} را از طریق f_{NN} با دو ویژگی ورودی M و $\sigma_{impl}\sqrt{\tau}$ آموزش دیده جهت حداقل کردن عبارات معادله (۲) جایگزین می کنیم. این حالت، متناظر با تخمین غیر پارامتری نسبت پوشش‌ریسک بهینه است که سبب حداقل شدن خطای واریانس پوشش‌ریسک می شود. هدف مطالعه شبکه‌های عصبی مصنوعی، بررسی حجم قابل توجهی از داده های تاریخی موجود، قابلیت تقریب این شبکه ها و در مواردی، مفروضات غیرواقع گرایانه از مدل های پارامتری اصلی است.

جهت تعیین عملکرد پوشش‌ریسک شبکه‌های عصبی، ما مدل های رگرسیون خطی را معرفی می کنیم که منجر به نسبت های پوشش‌ریسک خطی در چندین درجه حساسیت اختیارمعامله می شود. اثر اهرم، همبستگی منفی بین قیمت اصلی و نوسان آن را بیان می کند. جهت نشان دادن اهمیت این موضوع، اختیار خرید را در نظر بگیرید و فرض کنید که با دلتا بلک شولز $\delta_{BS} > ۰$، پوشش داده شده است. اگر در حال حاضر قیمت شاخص اصلی صعود کند، در این صورت قیمت اختیار خرید و موقعیت پوشش ریسک افزایش می یابد. با توجه به اثر اهرم، نوسان اصلی (ضمنی) نیز به صورت مشابه کاهش می یابد و این عامل، تاثیری منفی بر قیمت اختیارمعامله دارد. در واقع با برابری هر شاخص دیگر، قیمت های اختیار خرید و فروش با افزایش نوسان (ضمنی) آنها افزایش می یابد و شاخص وگا آنها، مثبت است. دلتا بلک شولز (δ_{BS})، این اثر اضافی را در نظر نمی گیرد. از آنجایی که ما صرفا پوشش‌ریسک را با شاخص اصلی انجام می دهیم، تغییرآشکار این است که فقط تاحدی پوشش داده شود،یعنی از نسبت پوشش ریسک $\delta_{LR} = a\delta_{BS}$ که a تخمین زده شده است،استفاده کنیم (در یک مجموعه آموزشی). در این خصوص، LR نشان دهنده رگرسیون خطی است. در این حالت، باید توجه داشت که می توان a>۱ را برای اختیار فروش و a<۱ را برای اختیار خرید در نظر گرفت.

عملکرد شبکه‌های عصبی مصنوعی و معیارها بر اساس قیمت های متوسط لحظه ای روزانه حاصل از اختیار معامله متریک و داده های لحظه ای بورس آلمان، ارزیابی می شود.همچنین ما طول Δt دوره پوشش ریسک را از ۱ ساعت تا ۲ روز تغییر می دهیم. به طور کلی، شبکه‌های عصبی مصنوعی عملکرد مطلوبی از حیث خطای میانگین مربعات نسبت به دلتا بلک شولز حتی در زمانی که این شاخص با نوسان ضمنی قراردادی استفاده می شود، دارد. با وجود این، استفاده از نسبت های پوشش‌ریسک رگرسیون خطی δ_{LR} عملکرد بسیار بهتری نسبت به δ_{NN} دارد. این شاخص ها منجر به کاهش ۲۰٪-۱۵٪ در خطای میانگین مربعات می شود.

تفسیر این مشاهدات گویای آن است که درجات حساسیت اختیارمعامله، در برگیرنده کلیه شاخص های غیر خطی مرتبط پیرامون داده‌های مورد نیاز برای پوشش‌ریسک است. بنابراین، شبکه عصبی قابلیت یادگیری اثر اهرم را دارد اما توانایی بهبود رگرسیون خطی ساده از جمله شاخص های درجه حساسیت اختیارمعامله را ندارد. سوال این است که ما چه چیزی را آموخته ایم؟ ما ابتدا در مورد عملکرد برتر شبکه‌های عصبی مصنوعی نسبت به دلتا بلک شولز در مجموعه داده های واقعی، رضایت یافتیم. هنگام بررسی آنچه شبکه عصبی در حال یادگیری است، مدل های رگرسیون خطی به عنوان رقبای طبیعی پدیدار شده اند. این مدل‌های آماری بسیار ساده هستند و در مورد چنین مدلی، صرفا دلتا بلک شولز با تعداد زیادی از مدل‌ها با چندین شاخص مشابه جایگزین می شود. با این حال، همان طور که می دانیم این مدل ها در منابع پژوهشی جهت تعیین مدل های پیچیده تر، استفاده نشده اند.

۲. قیمت های متوسط لحظه ای اس اندپی۵۰۰

ما قیمت های روزانه پیشنهادی و درخواستی بسته شدن اختیارهای معامله خرید و فروش را در اس اند پی۵۰۰ در بازه‌های زمانی ژانویه ۲۰۱۰ و ژوئن ۲۰۱۹ از اپشن متریکس، به دست آوردیم. ما قیمت متوسط را به عنوان قیمت واقعی بازار در نظر می‌گیریم.

[Downloaded from www.iem-science.ir on 2026-11-08]

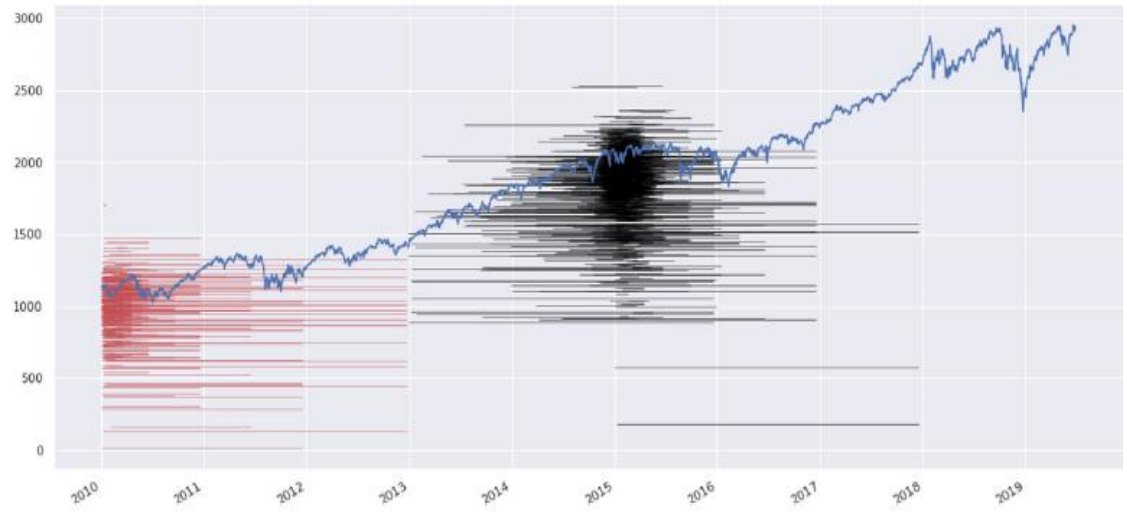
شکل نشان دهنده نمونه ای از اختیارهای معامله به دست آمده شامل اختیار فروش با مظنه قیمت در سه ماه نخست سال های ۲۰۱۰ یا ۲۰۱۵ است. درجات حساسیت برای بیشتر اختیارهای معامله ارائه شده و با داده های از دست‌رفته، جایگزین شدند. نتایج ارائه شده، کارایی مطلوبی جهت استفاده از درجات حساسیت محاسبه شده برای کلیه اختیارهای معامله یا درجات حساسیت ارائه شده توسط اپشن متریک دارند. نرخ های بهره مورد نیاز، از نرخ های ارائه شده اپشن متریک، درون یابی شدند. در مورد تاریخ های سررسید کمتر از یک هفته (که در این حالت اپشن متریک نرخ های متناظر را ارائه نمی‌کند)، از نرخ های تضمینی تامین مالی یک شبه بلومبرگ استفاده کردیم.

ما داده ها را در یک جدول به نحوی سامان داده ایم که هر سطر دقیقا متناظر با یک مشاهده به صورت یک اختیارمعامله در یک روز معاملاتی است (همراه با قیمت فردا جهت آموزش). ما نمونه های خاصی را حذف کردیم. به طور مثال، نمونه هایی با زمان- ارزش منفی، زمان سررسید کمتر از ۱ روز یا حجم معاملاتی صفر.

۳. داده‌های لحظه ای یورو استاکس ۵۰

ما از بورس آلمان که داده‌های لحظه ای اختیارمعامله شاخص یورو استاکس ۵۰ و اختیار آتی را در بازه‌های زمانی بین ژانویه ۲۰۱۶ و جولای ۲۰۱۸ ارائه کردند، تقدیر می کنیم

در این بخش، چگونگی پردازش این داده‌ها را بیان می کنیم. اگر چندین معامله در یک بازه‌زمانی یکسان انجام شوند، در این صورت این سفارشات را جمع کرده و قیمت میانگین وزنی- حجمی را در نظر می‌گیریم. ما هر تراکنش اختیارمعامله را با تازه ترین قیمت لحظه ای اختیار آتی و کوتاه ترین سر رسید تطبیق می‌دهیم (حجمی-وزنی اگر چندین معامله به صورت همزمان رخ دهند). این اختیارهای آتی که لیکویید ترین اختیارهای آتی محسوب می شوند، جهت پوشش موقعیت اختیارمعامله استفاده می شوند.



شکل ۱. نمونه ای از اختیارهای فروش به دست آمده همراه با فرآیند قیمت اصلی (اس اندپی۵۰۰) به رنگ آبی. صرفا اختیار معاملاتی در نظر گرفته شده اند که حجم معامله آنها در برخی از روزهای معامله، بیش از ۱۰۰۰ است. هر بخش خط قرمز (سیاه) نشان دهنده یک اختیار فروش است که برآورد قیمت آن در نیمه نخست سال ۲۰۱۰ (۲۰۱۵) بوده است. قیمت اعمال متناظر به عنوان یک مقدار در محور y نشان داده شده است. تغییرات عمودی تصادفی کوچک جهت افزایش پدیداری اختیارهای معامله اضافه شده‌اند.

[Downloaded from www.iem-science.ir on 2026-11-08]

٤. آماده سازی داده ها و راه اندازی آزمایشی

در این مطالعه، هدف ما تعیین نسبت پرچین δ به عنوان تابعی از مقادیر قابل مشاهده برای به حداقل رساندن واریانس در یک دوره از سبد سهام پوشش دار

$$(۵) \qquad = \delta S_۱ + (۱ + r_{onr}\Delta t)\,(C_۰ - \delta S_۰) - C_۱ V_۱^{\delta}$$

است. در اینجا $S_۰$ و $S_۱$ نشان دهنده قیمت های ابزار پوشش‌ریسک در ابتدا و انتهای دوره هستند و $C_۰$ و $C_۱$ نشان دهنده قیمت های اختیار خرید یا فروش هستند. هدف ما ارزیابی عملکرد یک شبکه عصبی مصنوعی (ANN) در تعیین نسبت پوشش بر اساس قیمت‌های متوسط پایان روز و داده‌های تیک است. این نتایج با مدل های رگرسیون خطی برای محاسبه δ مقایسه خواهند شد.

برای هر مجموعه داده، داده ها را به مجموعه های آموزش و آزمایش تقسیم می کنیم. هر دو مدل شبکه‌های عصبی مصنوعی و معیار فقط با استفاده از داده های درون نمونه آموزش داده می شوند. واریانس سبدسهام پوشش داده شده با میانگین مربعات خطای پوششی (MSHE) تقریب زده شده است. عملکرد هر روش بر روی مجموعه داده خارج از نمونه با استفاده از متریک میانگین مربعات خطا ارزیابی می‌شود.

محاسبه میانگین مربعات خطا به شرح زیر است:

$$\mathrm{var}(V_۱^{\delta}) \approx \mathrm{MSHE} = ۱/N_{test} * \sum_{t,j}^{Ntest} (۱۰۰\ V^{\delta}_{t+۱,j} / S_t)^{۸۲} \qquad (۶)$$

جایی که δ با استفاده از شبکه‌های عصبی مصنوعی یا رگرسیون خطی مدل‌سازی می‌شود. نمایه سازی و عادی سازی توسط ۱۰۰/ S_t برای مقایسه خطاها در مجموعه داده‌ها و دوره‌های زمانی انجام می‌شود. ضریب نرمال سازی ۱۰۰/ S_t امکان استانداردسازی اندازه‌گیری خطا را در بین گزینه ها و بازه‌های زمانی مختلف فراهم می‌کند.

برای آماده‌سازی داده‌ها، ما هر مجموعه داده را در یک چارچوب داده سازماندهی می‌کنیم و تمام نمونه‌های موجود را حذف می‌کنیم تا از تجزیه و تحلیل منسجم اطمینان حاصل کنیم. مجموعه داده اس اندپی۵۰۰ به ۱۴ پنجره زمانی سه ساله با همپوشانی هر کدام با نسبت ۵:۱ داده های درون نمونه به خارج از نمونه تقسیم شده است. برای آموزش شبکه‌های عصبی مصنوعی ، مجموعه نمونه ۹۰۰ روزه به ۷۲۰ روز آموزش و ۱۸۰ روز داده اعتبار تقسیم می شود. پنجره‌های زمانی ۱۸۰ روز یکبار جابه جا می شوند تا از همپوشانی در مجموعه خارج از نمونه جلوگیری شود. مجموعه داده یورواستاکس۵۰ کوتاه‌تر است و نیازی به تقسیم به پنجره‌های زمانی ندارد، با نسبت ۴:۱:۱ داده‌های درون نمونه به خارج از نمونه تقسیم‌بندی می‌شوند.

در عمل، مدل‌ها معمولاً به دفعات بیشتر مانند هفتگی یا روزانه، بازآموزی می‌شوند. با توجه به محدودیت‌های محاسباتی، ما هر ۱۸۰ روز یک بار در این مطالعه هر دو مدل شبکه‌های عصبی مصنوعی و معیار را دوباره آموزش می‌دهیم. مدل‌های معیار به همان شیوه رفتار می‌شوند و در فواصل زمانی مشابه شبکه‌های عصبی مصنوعی بازآموزی می‌شوند.

HedgeNeT

تحقیقات گسترده‌ای در مورد استفاده از شبکه‌های عصبی مصنوعی (ANN) درقیمت‌گذاری اختیار معاملات و پوشش‌ریسک انجام شده است. در پژوهشی شبکه‌های عصبی مصنوعی را به عنوان یک جایگزین ناپارامتری برای قیمت‌گذاری اختیارمعامله پیشنهاد کردند و نشان دادند که حتی شبکه‌های عصبی کوچک با گره های کمی نیز می توانند عملکرد خوبی داشته باشند.

شبکه عصبی مورد استفاده در این مطالعه، به نام HedgeNet، بر تنظیمات یک دوره ای تمرکز می‌کند و به جای محاسبه قیمت اختیارمعامله، مستقیماً ویژگی های آن را به نسبت پوشش‌دهی δ_{NN} نگاشت می کند. معماری HedgeNet شامل یک شبکه عصبی پیش‌خور چند لایه (FCNN) با دو لایه پنهان، فعال‌سازی ReLU و یک گره خروجی خطی برای δ_{NN} است. سپس یک ماژول

[Downloaded from www.iem-science.ir on 2026-11-08]

تبدیل غیرقابل آموزش δ_{NN} را به یک مقدار تکرار تبدیل می‌کند، که می‌تواند با به حداقل رساندن تفاوت‌های مجذور، به قیمت‌های اختیارمعامله مشاهده‌شده آموزش داده شود.

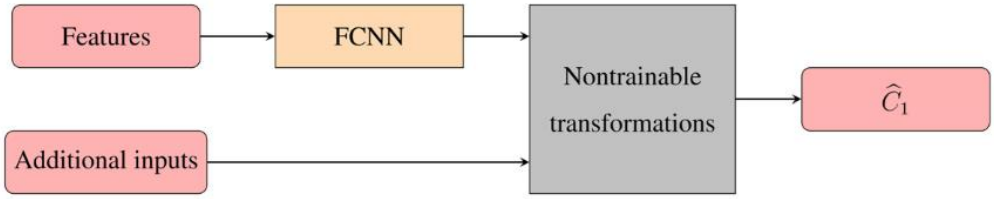
۵. معماری HedgeNet، پیاده سازی و آموزش آن

، ما از یک رویکرد شبکه عصبی دو بخشی برای به دست آوردن مستقیم نسبت پوشش طبق شکل و HedgeNetدر معماری شکل۳ استفاده می کنیم. بخش اول یک شبکه عصبی پیش‌خور چند لایه کاملاً متصل (FCNN) با دو لایه پنهان از ۳۰ گره است که توسط فعال‌سازی واحد خطی اصلاح‌شده (ReLU) به هم متصل شده‌اند. خروجی FCNN یک گره خطی است که مطابق با نسبت پوششی است که به عنوان δ_{NN} نشان داده شده است. معماری‌های مختلف، از جمله تغییرات در تعداد گره‌ها و لایه‌های پنهان، آزمایش شدند، اما نتیجه‌گیری کلی ثابت ماند.

بخش دوم HedgeNet یک ماژول تبدیل غیرقابل آموزش است که با اعمال معادله (۱) و در نظر گرفتن پرچم نوع اختیارمعامله (۱ برای فروش (put)، ۰ برای خرید (call)) برای حفظ برابری خرید-فروش، نسبت پوششی δ_{NN} را به مقدار تکرار $\hat{c}_1$ تبدیل می‌کند. . این ماژول از تبدیل های وابسته تشکیل شده است و بر ویژگی تقریب جهانی شبکه عصبی تأثیر نمی‌گذارد.

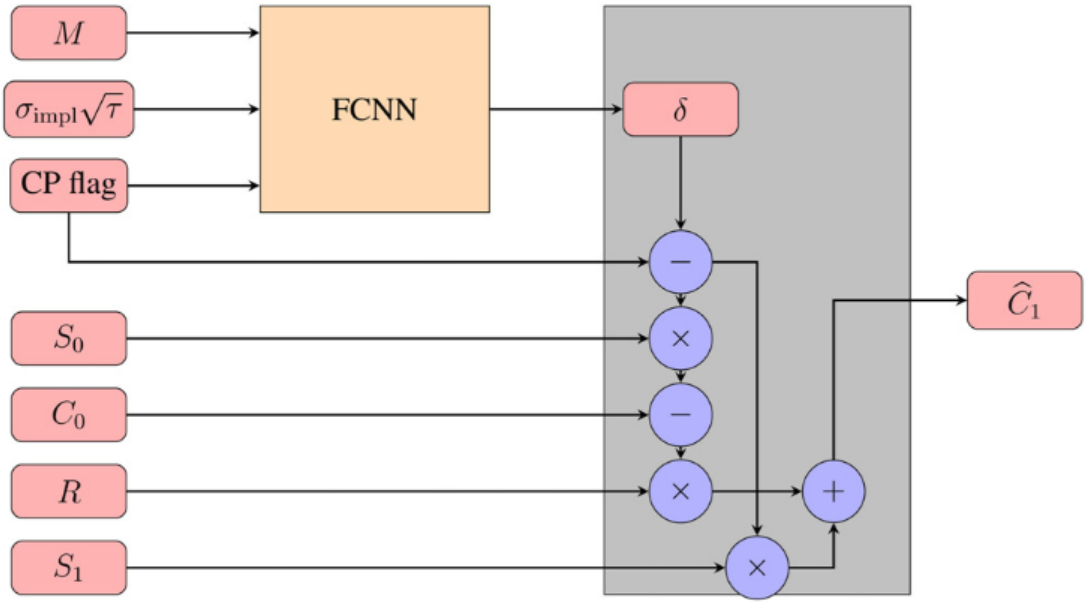
پیاده‌سازی HedgeNet با استفاده از چارچوب‌های یادگیری عمیق پایتون با تنسورفلور و کراس روی صفحه نمایش با شتاب GPU انجام می‌شود. استانداردسازی ورودی ها، مقدار دهی اولیه وزن خاویر و بهینه ساز آدام در طول تمرین اعمال می‌شود.

سه مجموعه ویژگی مختلف برای بخش قابل آموزش HedgeNet در نظر گرفته شده است. اولین مجموعه شامل نسبت مالی (M)، جذر واریانس ضمنی کل ($\sigma_{impl}\sqrt{\tau}$) و پرچم فراخوانی است. استفاده از نسبت مالی به جای قیمت پایه و قیمت اعتصاب به طور جداگانه عملکرد تعمیم را به دلیل ماهیت ثابت آن بهبود می بخشد. مجموعه ویژگی دوم شامل دلتا(δ_{BS}) ، وگا(V_{BS}) ، $1/\sqrt{\tau}$، و پرچم خرید-فروش برای ثبت اثر اهرمی است. مجموعه ویژگی سوم علاوه بر دلتا و وگا، وانا (Va_{BS}) را نیز در خود جای داده است. نتایج تجربی نشان می‌دهد که معماری و مجموعه ویژگی‌های HedgeNet نسبت‌های مصون‌سازی دقیقی را به دست می‌دهد، که امکان استراتژی‌های پوشش موثر در معاملات اختیار را فراهم می‌کند. طراحی دقیق و پیاده سازی عملکرد قوی، قابلیت اطمینان مدل شبکه عصبی را تضمین می‌کند.



شکل۲ . یک نمودار شماتیک از HedgeNet. ویژگی‌ها توسط یک شبکه عصبی پیش‌خور کاملاً متصل (FCNN) به یک موقعیت پوششی تبدیل می‌شوند. ورودی اضافی برای محاسبه مقدار C_1 سبددارایی در حال تکرار استفاده می شود.

[Downloaded from www.iem-science.ir on 2026-11-08]



شکل ۳ . یک ارائه شماتیک دقیق از HedgeNet می باشد. به یاد بیاورید که M=S۰/K نسبت مالی وσimpl$\sqrt{\tau}$ جذر واریانس ضمنی کل است. "CP flag" یک پرچم بولین برای اختیارمعامله فروش برابر۱ و برای اختیارمعامله خریدبرابر ۰ است . در مرحله بعد، S۰وS۱ قیمت های پایه در ابتدا و انتهای دوره پوشش دهی هستند، C۰ نشان دهنده قیمت اختیار معامله در ابتدای دوره، وC^۱ نشان دهنده ارزش تکرار است. در نهایت، R=۱+r_{onr} بازده یک شبه بدون ریسک است

معیار بلک شولز(BS[۱])

اکنون در مورد اینکه چگونه عملکرد پوشش‌دهی شبکه‌های عصبی مصنوعی را معیار قرار می‌دهیم، بحث می‌کنیم. یک معیار می تواند به هیچ وجه پوشش‌ریسک نداشته باشد، یعنی δ=۰. در این حالت، واریانس خطای پوشش فقط واریانس تغییر در قیمت اختیارمعامله است. منطقی تر این است که از دلتا بلک شولز به دست آمده از فرمول بلک شولز به عنوان معیار استفاده کنید.

پوشش‌ریسک از طریق دلتا بلک شولز یک معیاراستاندارد است که در آن از نوسانات ضمنی برای به دست آوردن پوشش استفاده می شود. با این حال، پوشش گسسته با استفاده ازدلتا بلک شولز می‌تواند منجر به خطا شود، حتی اگر داده‌ها از مدل بلک شولز شبیه‌سازی شده باشند.

برای بهبود دلتا بلک شولز ، می‌توانیم حساسیت‌های دیگری مانند گاما و وانا را پوشش‌دهی کنیم. یک مدل آماری را می توان به صورت زیر:

$$\delta = a\delta_{BS} + bV_{BS} + cVa_{BS} + d\partial_{BS} \qquad (۷)$$

فرموله کرد، که در آن a، b، c، و d برای خرید و فروش ها به طور جداگانه در هر مجموعه درون نمونه تخمین زده می شوند.ما همچنین نسبت پوشش پیشنهادی را که توسط فرمول زیر ارائه شده است، درج می کنیم:

$$\delta_{HW} = \delta_{BS} + V_{BS} / \sqrt{\tau}S\ (a + b\delta_{BS} + c\delta\hat{}^{۲}_{BS}) \qquad (۸)$$

که در آن τ تاریخ سررسید است.

[۱] black-Scholes Benchmark

[Downloaded from www.iem-science.ir on 2026-11-08]

علاوه بر این، ما یک مدل "Relaxed Hull-White" را معرفی می‌کنیم که در آن ضریب جلوی δ_{BS} به یک محدود نمی شود. این مدل‌ها «آماری» در نظر گرفته می‌شوند زیرا نسبت پوششی صرفاً از ملاحظات آماری به دست می‌آید.
سایر معیارهای ممکن می تواند شامل نسبت های پوششی مشتق شده از مدل های پارامتریک مانند مدل های نوسانات تصادفی باشد. نشان داده شده است که این مدل ها فقط در برخی موارد بهتر از دلتا بلک شولز عمل می کنند .ما همچنین دو معیار خطی

$$\delta_1 = aM + b\sigma_{impl}\sqrt{\tau} + c \quad (۹)$$

$$\delta_2 = N\,(aM + b\sigma_{impl}\sqrt{\tau} + c) \quad (۱۰)$$

را در نظر گرفتیم. اما دریافتیم که آنها بسیار بدتر از دلتای بلک شولز عمل می کنند.
به طور خلاصه، ما مدل‌های رگرسیون خطی مختلفی را برای محک زدن عملکرد پوشش‌دهی شبکه‌های عصبی مصنوعی ایجاد کرده‌ایم. این مدل ها حساسیت ها و پارامترهای مختلفی را برای بهبود دلتا بلک شولز سنتی در نظر می گیرند.

۶. نتایج

در این قسمت نتایج عملکرد مدل های مختلف آماری پوشش‌ریسک را بر حسب کاهش میانگین مربعات خطا بیان می کنیم. به طور کلی، نسبت های پوشش‌ریسک شبکه‌های عصبی عملکرد بهتری نسبت به مدل های رگرسیون خطی ندارند. در مجموعه داده اس اندپی۵۰۰، رگرسیون های هال-وایت و دلتا-وگا-وانا بهترین عملکرد را دارند به نحوی که رگرسیون هال-وایت عملکرد بهتری در دوره زمانی پوشش ریسک یک روزه داشته و رگرسیون دلتا-وگا-وانا عملکرد بهتری را در دوره تناوب دو روزه نشان می‌دهد. رگرسیون دلتا-وگا-گاما- وانا در مجموعه داده یورو استاکس ۵۰، بهترین عملکرد را از خود نشان می‌دهد. با این حال، تفاوت بین این رگرسیون های خطی با سه یا چهار ضریب، از نظر آماری یا اقتصادی معنادار نیستند.
شایان ذکر است که هر نمونه داده به نحوی نرمال شده است که قیمت اصلی S. در زمان ۰، ۱۰۰ است. در این صورت می‌توان خطاهای مطلق پوشش‌ریسک را در مجموعه داده‌های مختلف مقایسه کرد. همچنین توجه شود که ما صرفا اختیارهای خرید و فروش در زیان (در سود) را در نظر گرفته ایم.

پیشنهادات آتی

کارهای آینده برای این تحقیق می تواند شامل موارد زیر باشد:
۱- ترکیب منابع داده اضافی: استفاده از منابع داده اضافی مانند احساسات اخبار مالی، احساسات رسانه های اجتماعی یا شاخص های اقتصادی را برای افزایش دقت پیش بینی مدل شبکه عصبی کاوش کنید. با گنجاندن این منابع، این مدل می‌تواند احساسات بازار گسترده‌تر و رویدادهای بالقوه بازار را به تصویر بکشد.
۲- ادغام تکنیک های یادگیری عمیق: استفاده از تکنیک‌های یادگیری عمیق، مانند شبکه های عصبی مکرر (RNN) یا شبکه‌های عصبی کانولوشن (CNN) را برای پیش بینی قیمت سهام و پوشش ریسک بررسی‌کنید. مدل‌های یادگیری عمیق در ثبت الگوهای پیچیده و وابستگی‌های زمانی در داده‌های متوالی، که برای داده‌های بازار سهام قابل اعمال است، نویدبخش است.
۳- پیش‌بینی و معاملات بی‌درنگ: یک سیستم پیش‌بینی و معاملات بی‌درنگ ایجاد کنید که مدل شبکه عصبی آموزش‌دیده را در خود جای دهد. این سیستم می تواند به طور مداوم شرایط بازار را رصد کند، پیش بینی‌ها را در زمان واقعی به روز کند و معاملات را به صورت خودکار بر اساس استراتژی های مدیریت ریسک از پیش تعریف شده انجام دهد.

[Downloaded from www.iem-science.ir on 2026-11-08]

۴- **روش‌های مجموعه و ترکیب مدل:** استفاده از روش‌های مجموعه‌ای، مانند بسته‌بندی یا تقویت، برای ترکیب چندین شبکه عصبی یا سایر مدل‌های یادگیری ماشین برای بهبود دقت پیش‌بینی را بررسی کنید. یکپارچه سازی می تواند به کاهش خطر بیش از حد برازش و افزایش استحکام مدل کمک کند.

۵- توضیح پذیری و تفسیرپذیری: روش هایی را برای افزایش تفسیرپذیری پیش بینی های مدل شبکه عصبی بررسی کنید. این به ذینفعان امکان می‌دهد تا عوامل و ورودی‌هایی را که بیشتر در تصمیم‌گیری‌های مدل نقش دارند، درک کنند و اعتماد و پذیرش در برنامه‌های کاربردی دنیای واقعی را تسهیل می‌کند.

۶- یادگیری انتقال و تطبیق دامنه: کاربرد تکنیک های یادگیری انتقالی را بررسی کنید، جایی که دانش به دست آمده از آموزش در یک بازار سهام می‌تواند با داده های محدود به دیگری منتقل شود. این می‌تواند به غلبه بر چالش‌های کمبود داده و بهبود عملکرد پیش بینی در بازارهای سهام در حال ظهور یا کمتر مطالعه شده کمک کند.

۷- در نظر گرفتن رویدادهای ژئوپلیتیکی و عوامل کلان اقتصادی: رویدادهای ژئوپلیتیکی و عوامل کلان اقتصادی را که می‌توانند به طور قابل توجهی بر پویایی بازار سهام تأثیر بگذارند، در بر گیرند. این می تواند شامل توسعه تکنیک های جدید برای استخراج بینش از مقالات خبری، گزارش های اقتصادی یا گفتگوهای رسانه های اجتماعی برای بهبود قابلیت های پیش بینی مدل در پاسخ به چنین رویدادهایی باشد.

منابع

۱. P. C. Andreou, C. Charalambous, and S. H. Martzoukos. Pricing and trading European options by combining artificial neural networks and parametric models with implied parameters. European Journal of Operational Research, ۱۸۵(۳):۱۴۱۵–۱۴۳۳, ۲۰۰۸.

۲. P. C. Andreou, C. Charalambous, and S. H. Martzoukos. Generalized parameter functions for option pricing. Journal of Banking & Finance, ۳۴(۳):۶۳۳–۶۴۶, ۲۰۱۰.

۳. J. Bennell and C. Sutcliffe. Black–Scholes versus artificial neural networks in pricing FTSE ۱۰۰ options. Intelligent Systems in Accounting, Finance & Management: International Journal, ۱۲(۴):۲۴۳–۲۶۰, ۲۰۰۴.

۴. L. Blynski and A. Faseruk. Comparison of the effectiveness of option price forecasting: Black–Scholes vs. simple and hybrid neural networks. Journal of Financial Management & Analysis, ۱۹(۲):۴۶–۵۸, ۲۰۰۶.

۵. C. Boek, P. Lajbcygier, M. Palaniswami, and A. Flitman. A hybrid neural network approach to the pricing of options. In Proceedings of ICNN'۹۵–International Conference on Neural Networks, volume ۲, pages ۸۱۳–۸۱۷. IEEE, ۱۹۹۵.

۶. F. Black. Studies of stock market volatility changes. Proceedings of the American Statistical Association Business and Economic Statistics Section, ۱۹۷۶.

۷. C. Dugas, Y. Bengio, F. Belisle, C. Nadeau, and R. Garcia. Incorporating functional knowledge in neural networks. ´ Journal of Machine Learning Research, ۱۰(Jun):۱۲۳۹–۱۲۶۲, ۲۰۰۹.

۸. R. Garcia and R. Genc¸ay. Pricing and hedging derivative securities with neural networks and a homogeneity hint. Journal of Econometrics, ۹۴(۱-۲):۹۳–۱۱۵, ۲۰۰۰.

۹. J. Hull and A. White. Optimal delta hedging for options. Journal of Banking & Finance, ۸۲:۱۸۰–۱۹۰, ۲۰۱۷.

۱۰. J. M. Hutchinson, A. W. Lo, and T. Poggio. A nonparametric approach to pricing and hedging derivative securities via learning networks. The Journal of Finance, ۴۹(۳):۸۵۱–۸۸۹, ۱۹۹۴.

۱۱. P. Henry-Labord`ere. Generative models for financial data. SSRN ۳۴۰۸۰۰۷, ۲۰۱۹.

۱۲. M. Malliaris and L. Salchenberger. A neural network model for estimating option prices. Journal of Applied Intelligence, ۳(۳):۱۹۳–۲۰۶, ۱۹۹۳b.

[Downloaded from www.iem-science.ir on 2026-11-08]

۱۳. F. Mostafa and T. Dillon. A neural network approach to option pricing. WIT Transactions on Information and Communication Technologies, ٤١:٧١–٨٥, ٢٠٠٨.
١٤. P. Testing the monotonicity property of option prices. ´ The Journal of Derivatives, ١٤(٢):٦١–٧٦, ٢٠٠٦.
١٥. J. Ruf, W. Wang, Hedging with linear regressions and neural networks, Journal of Business &Economic Statistics, ٢٠٢١.

[Downloaded from www.iem-science.ir on 2026-11-08]