



مدل بهینه شبکه های عصبی مصنوعی برای پیش بینی قیمت اختیار تحت مدل دارایی *SVSI*

فاطمه فکوری لیاولی^۱، امیر محمدزاده^{۲*} و علی بلفکه^۳

تاریخ دریافت: ۱۴۰۲/۱۲/۲۹ و تاریخ پذیرش: ۱۴۰۳/۵/۲۲

چکیده

در این پژوهش با در نظر گرفتن محدودیتهای موجود مدل بلک شولز در قیمت گذاری اختیار، مدلی جدید ارائه شده است که نوسانات و نرخ بهره تصادفی را در نظر می گیرد. پس از ارائه این مدل تحت حالتی خاص، با اجرای روش یادگیری عمیق بر روی داده های شبیه سازی شده از فرمول فرم بسته، روشهای مونت کارلو و مونت کارلو شرطی مدل یادگیری عمیق ساخته و در نهایت با اعمال حالتیهای مختلفی روی مدل که دارای کمترین خطا نیز باشد مدل بهینه یادگیری عمیق معرفی می گردد. نتایج نشان می دهد که کارایی این مدل، از نظر زمان و دقت نسبت به روش های سنتی مانند روش مونت کارلو بیشتر است. نتایج این پژوهش می تواند به عنوان یک ابزار کاربردی برای تصمیم گیری های سرمایه گذاری و مدیریت ریسک مورد استفاده قرار گیرد.

واژه های کلیدی: یادگیری عمیق، قیمت گذاری اختیار، نوسان تصادفی، نرخ بهره تصادفی، روش مونت کارلو.

۱. دانشجوی دکتری گروه مهندسی مالی، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران.
۲. دانشیار گروه مهندسی مالی، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران، (نویسنده مسئول)؛
A.Mohammadzadeh@qiau.ac.ir
۳. کارشناس ارشد گروه ریاضی مالی، دانشکده علوم پایه، دانشگاه اراک، اراک، ایران.

مقدمه

اختیار معامله موقعیت خاصی را در بازار اوراق مشتقه به خود اختصاص می‌دهد. محققان، سفته‌بازان و سایر معامله‌گران همگی امیدوارند که برای هر اختیار، قیمت مناسبی دریافت کنند. تنها اختیارهای محدودی وجود دارد که می‌توانیم راه‌حل دقیقی برای قیمت آنها به دست آوریم، و برای اکثر اختیارها نیاز داریم تا قیمت را به صورت عددی بدست آوریم. روش کلاسیک در پردازش مجموعه داده‌های بزرگ و داده‌های با ابعاد بالا ضعیف و محاسبه آن کند است. با توسعه هوش مصنوعی در سال‌های اخیر، مانند روش‌های یادگیری عمیق، بهینه‌سازی مقادیر هدف آسان‌تر و آسان‌تر شده است. بنابراین برخی از محققان، سرمایه‌گذاران و معامله‌گران شروع به مراقبت از کاربرد هوش مصنوعی در انواع مختلف قیمت‌گذاری اختیار کردند (Gan, L., Wang, H., & Yang, Z. 2020). در این پژوهش با استفاده از مدل آموزشی قیمت‌گذاری اختیار بلک-شولز در شبکه‌های یادگیری عمیق (Culkin, R., & Das, S. R. 2017)، یک مدل برای پیش‌بینی قیمت‌گذاری اختیار تحت مدل SVSI در شبکه‌های یادگیری عمیق آموزش می‌دهیم، این مدل آموزش دیده نشان می‌دهد که می‌توان از شبکه‌های یادگیری عمیق برای یادگیری مدل‌های قیمت‌گذاری اختیار تحت مدل SVSI در بازارهای مختلف استفاده کرد.

مبانی نظری و پیشینه پژوهش

در دو دهه گذشته مدل‌های جدیدی از قیمت‌گذاری اختیار معامله ظاهر شده‌اند که برخی از مفروضات محدودکننده بلک-شولز^۱ را کاهش می‌دهد. بنابراین مفروضات نوسان ثابت و نرخ بهره ثابت بر خلاف واقع غالب شده‌اند. بر خلاف مدل قیمت‌گذاری اختیار مرتون^۲ Black, (F., & Scholes, M. 1973) مدل مشابهی که توسط امین^۳ و جارو^۴ (Amin, K. I., & Jarrow, R. A. 1992) معرفی شد به نرخ‌های بهره اجازه می‌دهد تا تصادفی باشند که ریسک نرخ بهره را شامل می‌شود. دسته دوم از مدل‌های اختیار، نوسان تصادفی شرطی را برای دارایی پایه می‌پذیرند، اما فرض نرخ بهره ثابت را حفظ می‌کنند. این دسته از مدل‌ها شامل: مدل کاکس و راس^۵ (Cox, J. C., & Ross, S. A. 1976) و مدل‌های نوسان تصادفی بیلی و استولز^۶ (Bailey, W., & Stulz, R. M. 1989)، بیتس^۷ (Betes, D. 1996) و هستون^۸ (Heston, S. L. 1993) هستند. باکشی^۹ و چن^{۱۰} (Bakshi, G. S., & Chen, Z. 1997) و اسکات^{۱۱} (Scott, L. O. 1997) فرمول‌های اختیار سهام به فرم بسته را توسعه داده‌اند که نوسانات تصادفی و نرخ بهره تصادفی SVSI را در نظر

1 Black-Scholes

2 Merton

3 KAUSHIK I. AMIN

4 ROBERT A. JARRO

5 Cox-Ross

6 Bailey-Stulz

7 Betes

8 Heston

9 Bakshi

10 Chen

11 Scott

می‌گیرد. در نتیجه تلاش‌های آن‌ها باعث شده که مفروضات بلک شولز مبنی بر نوسان ثابت و نرخ‌های بهره ثابت، به نوعی کاهش یابند. عملاً این فرمول‌های قیمت‌گذاری به اندازه کافی منجر به بهبود قابل توجهی در قیمت‌گذاری و عملکرد پوشش ریسک نسبت به مدل بلک-شولز شدند. یک نسخه سازگار با اجرای این دو (باکشی، چن و اسکات) ارائه می‌شود که هم نرخ‌های بهره تصادفی و نوسانات تصادفی را در خود جای داده است و هم تا حد ممکن شبیه مدل بلک-شولز است. حال با توجه به ضریب همبستگی $(\rho_{S,R})$ حرکت براونی‌های مدل دینامیکی نرخ بهره تصادفی (W_R) و مدل دینامیکی دارایی پایه W_S می‌توان قیمت اختیار خود را به دست آورد: یعنی اگر $\rho_{S,R} = 0$ باشد، آنگاه می‌توان فرمول فرم بسته و صریحی برای قیمت اختیار ارائه داد (Bakshi, G., Cao, C., & Chen, Z. 2010). شبیه سازی مونت کارلو^۱ برای اولین بار توسط استانیسلاو اولام^۲ در دهه ۱۹۴۰ توسعه یافت (Boyle, P. P. 1977). اولام یک ریاضیدان بود که روی پروژه منهن کار می‌کرد. در ابتدا این روش برای حل مسئله تعیین میانگین مسافتی که نوترون‌ها از مواد مختلف طی می‌کنند، استخراج شد. این روش از کازینو مونت کارلو در موناکو نامگذاری شد، زیرا تصادفی بودن نتایجی که برای بازی‌هایی مانند رولت یا تاس بسیار مهم است برای شبیه سازی مونت کارلو ضروری است. در اصل شبیه سازی مونت کارلو را می‌توان تقریباً در هر مسئله احتمالی استفاده کرد. این مسئله توضیح می‌دهد که چرا می‌توان از آن در زمینه‌های مختلف از جمله آمار، مالی، مهندسی و علوم استفاده کرد. ایده اصلی در پشت شبیه سازی مونت کارلو، نمونه‌گیری تصادفی مکرر از ورودی‌های متغیر تصادفی و جمع‌آوری نتایج است. به متغیر با ماهیت احتمالی یک مقدار تصادفی اختصاص داده می‌شود، سپس مدل بر اساس مقدار تصادفی محاسبه می‌شود. نتیجه مدل ثبت و فرآیند تکرار می‌شود. معمولاً این فرآیند صدها یا هزاران بار تکرار شده و هنگامی که شبیه سازی کامل شد، می‌توان نتایج را برای تعیین مقدار تخمینی به طور میانگین محاسبه کرد. (Metropolis, N., & Ulam, S. 1949). در این پژوهش از روش‌های شبیه سازی مونت کارلو استاندارد و مونت کارلو شرطی برای تقریب قیمت اختیار تحت مدل SVSI استفاده می‌شود. فناوری یادگیری ماشینی بسیاری از جنبه‌های جامعه مدرن را تقویت می‌کند؛ از جستجوهای وب و فیلتر کردن محتوا در شبکه‌های اجتماعی گرفته تا توصیه‌هایی در وبسایت‌های تجارت الکترونیک، و به طور فزاینده‌ای در محصولات مصرفی مانند دوربین‌ها و گوشی‌های هوشمند وجود دارد. سیستم‌های یادگیری ماشینی برای شناسایی اشیاء در تصاویر، رونویسی گفتار به متن، تطبیق اخبار، پست‌ها یا محصولات با علائق کاربران و انتخاب نتایج مرتبط از جستجو استفاده می‌شوند (Statt, N. 2018). یادگیری عمیق^۳ زیرمجموعه‌ای از یادگیری ماشینی یا در اصل یک شبکه عصبی با سه لایه یا بیشتر است. این شبکه‌های عصبی تلاش می‌کنند تا رفتار مغز انسان را شبیه‌سازی کنند و به آن اجازه می‌دهند از مقادیر زیادی داده «یاد بگیرند». در حالی که یک شبکه عصبی با یک لایه هنوز هم نمی‌تواند پیش‌بینی‌های تقریبی انجام دهد، لایه‌های پنهان اضافی می‌توانند به بهینه‌سازی و اصلاح مدل برای دقت کمک کنند (Statt, N. 2018). یادگیری عمیق بسیاری از برنامه‌ها و خدمات هوش مصنوعی را هدایت می‌کند، اتوماسیون را بهبود می‌بخشد و وظایف تحلیلی و فیزیکی را بدون دخالت انسان انجام می‌دهد. فناوری یادگیری عمیق در محصولات و خدمات روزمره (مانند کنترل از راه دور تلویزیون با قابلیت صوتی و تشخیص تقلب در کارت اعتباری) و همچنین فناوری‌های نوظهور

1 Monte Carlo

2 Stanislaw M. Ulam

3 Deep Learning

(مانند خودروهای خودران) نهفته است (Heaton, J. B., Polson, N. G., & Witte, J. H. 2016). سیستم‌های یادگیری عمیق همانگونه که به مقادیر زیادی داده نیاز دارند تا نتایج دقیق را برگردانند به سخت‌افزار قدرتمندی نیز نیاز دارند تا محاسبات پیچیده ریاضی را انجام دهند. بر این اساس اطلاعات به عنوان مجموعه داده‌های عظیم تغذیه می‌شود. هنگام پردازش داده‌ها شبکه‌های عصبی مصنوعی می‌توانند داده‌ها را با پاسخ‌های دریافتی از یک سری سؤالات دودویی درست یا غلط که شامل محاسبات ریاضی بسیار پیچیده است، طبقه‌بندی کنند. برای مثال یک برنامه تشخیص چهره با یادگیری تشخیص و تشخیص لبه‌ها و خطوط چهره و سپس بخش‌های مهم‌تر از چهره‌ها، و در نهایت، نمایش کلی چهره‌ها کار می‌کند. با گذشت زمان برنامه خود را آموزش می‌دهد و احتمال پاسخ‌های صحیح افزایش می‌یابد. در این صورت برنامه تشخیص چهره با گذشت زمان چهره‌ها را به دقت شناسایی می‌کند (Ferguson, R., & Green, A. 2018). تمام کتابخانه‌هایی که عموماً برای یادگیری عمیق استفاده می‌شوند متن باز هستند و تعدادی از آنها به شرح زیر است:

تسورفلو (TensorFlow)، تورچ (Torch)، تیانو (Theano) و کافه (Caffe)

در این پژوهش از کتابخانه تسورفلو برای ساخت مدل خود در یادگیری عمیق استفاده شده است.

روش شناسایی پژوهش

مدل دارایی و قیمت اختیار

مطالعات اخیر مدل بلک-شولز را برای ترکیب نرخ‌های بهره تصادفی یا نوسانات تصادفی توسعه داده‌اند. اما هنوز هیچ مطالعه تجربی جامعی وجود ندارد که نشان دهد آیا هر یک از ویژگی‌های تعمیم‌یافته، قیمت‌گذاری اختیار و عملکرد پوشش ریسک را بهبود می‌بخشد یا خیر. ابتدا یک مدل اختیار به صورت فرم بسته توسعه داده شده که هم نوسانات تصادفی و هم نرخ‌های بهره تصادفی را می‌پذیرد و از نظر تعداد، پارامترهای بسیار کم است. به طور کلی، فرمول قیمت‌گذاری اختیار $SVSI$ بر حسب قیمت سهام پایه، تلاطم سهام و نرخ بهره کوتاه مدت بیان می‌شود. فرض بر این است که هر یک از تلاطم لحظه‌ای و نرخ بهره کوتاه مدت از یک فرآیند بازگشت میانگین مارکوف پیروی می‌کنند. در نتیجه، چهارده پارامتر ساختاری باید به عنوان ورودی مدل برآورد شوند. این پارامترها را می‌توان با استفاده از روش تعمیم یافته لحظه‌ها (GMM) هانسن (Hansen, L. P. 1982) تخمین زد، همانطور که برای مثال در اندرسن و لوند (Andersen, T. G., & Lund, J. 1997) و چان و همکاران (Chan, K. C., Karolyi, G. A., Longstaff, F. A., & Sanders, A. B. 1992) انجام شده است. برای تعیین قیمت اختیار به قیمت سهام در زمان t تحت $SVSI$ نیاز به مدل داریم که این مدل را به صورت زیر معرفی می‌کنیم (Bakshi, G., Cao, C., & Chen, Z. 2010)

اختیار خرید اروپایی را که روی سهام S نوشته شده است، با قیمت اعمال K و با تاریخ سررسید T در نظر بگیرید. اگر قیمت اختیار در زمان t آن با G_t نشان داده شود و (S, R, V) یک فرآیند مارکوف باشد (R فرآیند نرخ بهره و V فرآیند تلاطم

باشد)، قیمت اختیار C باید تابعی از $S(t)$ ، $V(t)$ و $R(t)$ باشد. یک فرآیند دارایی سهام $S(t)$ را در نظر بگیرید که در آن تلاطم تصادفی $V(t)$ و مدل نرخ بهره تصادفی $R(t)$ به صورت معادله SDE

$$\begin{cases} \frac{dS(t)}{S(t)} = R(t)dt + \sqrt{V(t)}dW_S \\ dR(t) = [\theta_R - k_R R(t)]dt + \sigma_R \sqrt{R(t)}dW_R \\ dV(t) = [\theta_V - k_V V(t)]dt + \sigma_V \sqrt{V(t)}dW_V \end{cases} \quad (1)$$

نشان داده می شود. که در آن dW_S ، dW_V و dW_R سه حرکت براونی استاندارد هستند، که به صورت

$$Cov(dW_S dW_V) = \rho_{S,V}, \quad Cov(dW_S dW_R) = \rho_{S,R} dt, \quad Cov(dW_V dW_R) = 0$$

تعریف می شوند. پارامترهای k_V نرخ بازگشت به واریانس بلند مدت قیمت سهام، θ_V واریانس بلند مدت قیمت سهام، σ_V نوسان تلاطم، k_R نرخ بازگشت به نرخ بهره بلند مدت قیمت سهام، θ_R نرخ بهره بلند مدت، σ_R نوسان نرخ بهره تعریف می شود.

که در آن $k_V = \bar{k}_V + \lambda_V$ و $k_R = \bar{k}_R + \lambda_R$ ، λ_V و λ_R به ترتیب دو ثابت حق بیمه های ریسک در نرخ بهره و نوسان تعریف می شوند. \bar{k}_V و \bar{k}_R به ترتیب تنظیم درجه تندی (سرعت) در نرخ بهره و نوسان با مقدار ثابت $\frac{\theta_V}{k_V}$ و $\frac{\theta_R}{k_R}$ است. براساس نتایج هریسون^۱ و کریس^۲ (Harrison, J. M., & Kreps, D. M. 1979)، هیچ ناهار رایگانی در اقتصاد و بازارهای مالی وجود ندارد، اگر و تنها اگر معیاری معادل مارتینگل وجود داشته باشد که با آن بتوان ادعاها را طوری ارزیابی کرد که گویی سود ریسک خنثی است. به عنوان مثال، در زمان t قیمت $B(t, \tau)$ از یک اوراق قرضه کوپن صفر که ۱ دلار در دوره های τ پرداخت میکند را می توان به طریق

$$B(t, \tau) = E_Q \left[\exp \left(- \int_t^{t+\tau} R(s) ds \right) \right]$$

تعیین کرد. امید را با توجه به یک اندازه مارتینگل معادل و شرطی با اطلاعات تولید شده توسط $R(t)$ و $V(t)$ نشان می دهد. یعنی بر اساس معیار مارتینگل، سهام نباید نه بیشتر و نه کمتر از نرخ بدون ریسک سود کسب کنند. با این تنظیمات، امید شرطی را در معادله بالا برای مدل فوق حل می کنیم و معادله آشنای قیمت اوراق قرضه را به دست می آوریم.

$$B(t, \tau) = \exp[-\varphi(\tau) - \varrho(\tau)R(t)] \quad (2)$$

که در آن،

$$\varphi(\tau) = \frac{\theta_R}{\sigma_R} \left\{ (\zeta - k_R)\tau + 2 \ln \left[1 - \frac{(1 - e^{-\zeta\tau})(\zeta - k_R)}{2\zeta} \right] \right\},$$

¹ Harrison

² Kreps

$$\varrho(\tau) = \frac{2(1 - e^{-\zeta\tau})}{2\zeta(1 - e^{-\zeta\tau})(\zeta - k_R)}$$

$$\zeta = \sqrt{k_R^2 + 2\sigma_R^2}$$

نشان داده می‌شوند. با توجه به (Bakshi, G., Cao, C., & Chen, Z. 2010) فرمول دقیق صریح برای قیمت اختیار خرید

اروپایی تحت SVSI با فرض این که $\rho_{S,R} = 0$ ، به صورت

$$C(t,\tau) = S(t)\Pi_1(t,\tau) + KB(t,\tau)\Pi_2(t,\tau) \quad (3)$$

نشان داده می‌شود. که در آن $\Pi_1(t,\tau)$ و $\Pi_2(t,\tau)$ احتمال های ریسک خنثی هستند که از معکوس توابع مشخصه به

دست می‌آیند. $\Pi_j(t,\tau), j = 1,2$ به صورت

$$\Pi_j(t,\tau) = \frac{1}{2} + \frac{1}{\pi} \int_0^\infty RE \left[\frac{e^{-i\phi \ln(K)} f_j(t,\tau)}{i\phi} \right] d\phi, \quad j = 1,2.$$

تعریف می‌شوند که برای $f_j(t,\tau), j = 1,2$ داریم

$$f_1(t,\tau) = \exp(A_1 + B_1 + C_1 + D_1 + E_1)$$

$$A_1 = -\frac{\theta_R}{\sigma_R^2} \left[2 \ln \left(1 - \frac{(\xi_R - k_R)(1 - e^{-\xi_R\tau})}{2\xi_R} \right) + (\xi_R - k_R)\tau \right]$$

$$B_1 = -\frac{\theta_V}{\sigma_V^2} \left[2 \ln \left(1 - \frac{(\xi_V - k_V + (1 + i\phi)\rho\sigma_V)(1 - e^{-\xi_V\tau})}{2\xi_V} \right) + (\xi_V - k_V + (1 + i\phi)\rho\sigma_V)\tau \right]$$

$$C_1 = i\phi \ln(S)$$

$$D_1 = \frac{2i\phi(1 - e^{-\xi_R\tau})}{2\xi_R - (\xi_R - k_R)(1 - e^{-\xi_R\tau})} R$$

$$E_1 = \frac{i\phi(i\phi + 1)(1 - e^{-\xi_V\tau})}{2\xi_V - (\xi_V - k_V + (1 + i\phi)\rho\sigma_V)(1 - e^{-\xi_V\tau})} V$$

$$\xi_R = \sqrt{k_R^2 - 2\sigma_R^2 i\phi}$$

$$\xi_V = \sqrt{[k_V - (1 + i\phi)\rho\sigma_V]^2}$$

$$f_2(t,\tau) = \exp(A_2 + B_2 + C_2 + D_2 + E_2)$$

$$A_2 = -\frac{\theta_R}{\sigma_R^2} \left[2 \ln \left(1 - \frac{(\xi_R^* - k_R)(1 - e^{-\xi_R^*\tau})}{2\xi_R^*} \right) + (\xi_R^* - k_R)\tau \right]$$

$$\begin{aligned}
 B_2 &= -\frac{\theta_V}{\sigma_V^2} \left[2 \ln \left(1 - \frac{(\xi_V^* + i\phi\rho\sigma_V)(1 - e^{-\xi_V^*\tau})}{2\xi_V^*} \right) + (\xi_V^* - k_V + i\phi\rho\sigma_V)\tau \right] \\
 C_1 &= i\phi \ln(S) - \ln(B(t, \tau)) \\
 D_2 &= \frac{2(i\phi - 1)(1 - e^{-\xi_R^*\tau})}{2\xi_R^* - (\xi_R^* - k_R)(1 - e^{-\xi_R^*\tau})} R \\
 E_2 &= \frac{i\phi(i\phi - 1)(1 - e^{-\xi_V^*\tau})}{2\xi_V^* - (\xi_V^* - k_V + (1 + i\phi)\rho\sigma_V)(1 - e^{-\xi_V^*\tau})} V \\
 \xi_R^* &= \sqrt{k_R^2 - 2\sigma_R^2(i\phi - 1)} \\
 \xi_V^* &= \sqrt{[k_V - i\phi\rho\sigma_V]^2 - i\phi(i\phi - 1)\sigma_V^2}
 \end{aligned}$$

که در آن $\tau = T$ است. فرض کنید که تابع قیمت گذاری اختیار در تاریخ سررسید T ، $h(S(T))$ است، به عنوان مثال. برای قیمت اختیار خرید اروپایی $(\cdot, K, \max(S(T) - K, \cdot)) = h(S(T))$ است. با قضیه قیمت گذاری مارتینگل، قیمت اختیار معامله در زمان t که با $V(t, S, V, R)$ نشان داده می شود، می تواند به صورت

$$V(t, S, V, R) = \mathbb{E} \left[e^{-\int_t^T R(s) ds} h(S(T)) | S(t) = S, V(t) = V, R(t) = R \right] \quad (4)$$

بیان شود که امید ریاضی $\mathbb{E}[\cdot]$ در ریسک خنثی محاسبه می شود. با توجه به قیمت اولیه دارایی S_0 ، واریانس V_0 و نرخ بهره R_0 ، قیمت اختیار اروپایی در زمان اولیه برابر است با:

$$V(0, S_0, V_0, R_0) = \mathbb{E} \left[e^{-\int_0^T R(s) ds} h(S(T)) \right]$$

برای محاسبه قیمت اختیار معامله براساس فرمول فوق می توان از شبیه سازی مونت کارلو استفاده کرد. از نمونه های بازده قیمت میانگین گرفته و از میانگین نمونه به عنوان تخمین قیمت اختیار استفاده می کنیم. بنابراین چارچوب شبیه سازی مونت کارلو شرطی برای تخمین قیمت اختیار را پیشنهاد می کنیم.

شبیه سازی مونت کارلو

شبیه سازی مونت کارلو نوعی شبیه سازی است که برای محاسبه نتایج به نمونه گیری تصادفی مکرر و تجزیه و تحلیل آماری متکی است. این روش شبیه سازی بسیار نزدیک به آزمایش های تصادفی است، آزمایش هایی که در آن نتیجه خاصی از قبل مشخص نیست. در این زمینه، شبیه سازی مونت کارلو را می توان به عنوان روشی موثر برای تخمین و یا پیش بینی قیمت اختیار در نظر گرفت (Choe, G. H. 2016). شبیه سازی مونت کارلو معمولاً در قیمت گذاری اختیارات سهام استفاده می شود. قیمت های یک سهم پایه برای هر مسیر قیمتی ممکن، شبیه سازی می شود و سود اختیار برای هر مسیر تعیین می شود. سپس بازده ها به

طور میانگین محاسبه می‌شوند که ارزش فعلی یک اختیار را ارائه می‌دهد. به طور کلی برای یک مسئله ساده مونت کارلو (MC)، کمیتی را که می‌خواهیم بدانیم به عنوان مقدار مورد انتظار یک متغیر تصادفی X بیان می‌کنیم مانند $\mu = E(X)$. سپس به طور مستقل و تصادفی X_1, \dots, X_n را از توزیع آن نمونه برداری کرده و میانگین آن‌ها را محاسبه می‌کنیم.

$$\hat{\mu}_n = \frac{1}{n} \sum_{i=1}^n X_i. \quad (5)$$

و به عنوان تخمین μ در نظر می‌گیریم. قانون اعداد بزرگ تضمین می‌کند که با افزایش تعداد نمونه‌های تصادفی، این تخمین به مقدار صحیح همگرا می‌شود. با این حال معمولاً وضعیت کمی پیچیده‌تر است، به این معنا که X خود تابعی از متغیر تصادفی دیگری است ($Glasserman, P. 2004$). در این مورد، قانون اعداد بزرگ کولموگروف دلالت دارد: $E[f(X)]$

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n f(X_i)$$

بنابراین برای یک ثابت n روش‌های مونت کارلو تخمین‌های بی‌طرفانه‌ای از $E[f(X)]$ (Choe, G. H. 2016) ارائه می‌دهند.

یک مفهوم اساسی تئوری قیمت گذاری دارایی این است که تحت شرایط نامشخص، قیمت اوراق مشتقه می‌تواند به عنوان یک ارزش مورد انتظار نمایش داده شود. بنابراین در ارزش گذاری مشتقات مانند اختیارات، امید ریاضی کاهش می‌یابد. به همین دلیل MC روش مناسبی برای قیمت گذاری اختیار است ($Glasserman, P. 2004$). با توجه به پارامترهای یک مدل و شرایط اولیه، می‌توان دینامیک قیمت سهام را شبیه‌سازی کرد. معادله (3) با توجه به گسسته سازی اویلر روبه جلو به صورت زیر بازنویسی می‌شود:

$$S(t_{k+1}) = S(t_k) e^{R(t_k)^+ dt + S(t_k) \sqrt{V(t_k)^+} dW_{S,k+1}}$$

$$R(t_{k+1}) = [\theta_R - k_R R(t_k)^+] dt + \sigma_R \sqrt{R(t_k)} dW_{R,k+1} \quad (6)$$

$$V(t_{k+1}) = [\theta_V - k_V V(t_k)^+] dt + \sigma_V \sqrt{V(t_k)^+} dW_{V,k+1}$$

که در آن $x^+ = \max(x, 0)$ و $k = 1, 2, \dots, N$ است. فرض کنید $E[(X)^2] < \infty$ و انحراف معیار X را با $\sigma := pE[(f(X) - E[f(X)])^2]$ و خطای مونت کارلو را با

$$\epsilon_n := E[(f(X))] - \frac{1}{n} \sum_{i=1}^n f(X_i) \quad (7)$$

نشان می‌دهیم. میانگین مربعات خطا، $\frac{\sigma}{\sqrt{n}}$ برآورد می‌کند. بنابراین، خطا در شبیه‌سازی مونت کارلو به صورت $\frac{\sigma}{\sqrt{n}}$ است. توجه داشته باشید که کنترل خطا فقط در امید، هیچ اطلاعاتی در مورد خطای مسیرهای واقعی شبیه‌سازی شده ارائه نمی‌دهد. خطا

متناسب با انحراف استاندارد متغیر تصادفی $f(X)$ است، بنابراین کارایی شبیه‌سازی‌های MC را می‌توان با کاهش $Var[f(X)]$ از طریق تکنیک کاهش واریانس بهبود داد. دو استراتژی اصلی برای کاهش واریانس وجود دارد: بهره‌گیری از ویژگی‌های مدل برای تنظیم خروجی‌های شبیه‌سازی و کاهش نوسانات ورودی‌های شبیه‌سازی، به طور خاص در میان تکنیک‌های مختلف موجود، روش مونت کارلو شرطی را در (Metropolis, N., & Ulam, S. 1949) مورد بحث قرار می‌دهیم.

مفاهیم یادگیری ماشین در مالی

امور مالی یک علم مدیریت پول در شرایط عدم قطعیت است که نشان دهنده یک بازده طبیعی برای استفاده از هوش مصنوعی است. در حالی که پردازش اطلاعات مرسوم با مفروضات توزیع احتمال و تفسیر محدود می‌شود، فناوری یادگیری عمیق به ما کمک می‌کند تا الگوهای پیچیده‌ای را در داده‌ها به روشی بدون مدل کشف کنیم (Statt, N. 2018). هوش مصنوعی علم جدیدی است که انقلاب صنعتی چهارم را به وجود می‌آورد. موج اول روش‌های هوش مصنوعی با استفاده از شبکه‌های عصبی در سال ۱۹۸۰ با ظهور الگوریتم پس‌انتشار همراه شد. در موج دوم پیشرفت‌هایی در چارچوب‌های تکنولوژیکی برای سخت افزار و نرم افزار و پذیرش بیشتر در زمینه اجتماعی و اقتصادی ایجاد شده است. و همین باور در زمینه یادگیری عمیق عامل نتایج شگفت‌انگیزی است، که در طیف گسترده‌ای از کاربردها به دست آمده است. یادگیری ماشین، مطالعه علمی الگوریتم‌ها و مدل‌های آماری است که سیستم‌های کامپیوتری برای انجام یک کار خاص بدون برنامه‌ریزی صریح استفاده می‌کنند. الگوریتم‌های یادگیری در بسیاری از برنامه‌هایی که روزانه از آنها استفاده می‌کنیم وجود دارد. برای مثال یکی از دلایلی که یک موتور جستجوی وب مانند گوگل، بسیار خوب کار می‌کند، الگوریتم یادگیری است که یاد گرفته چگونه صفحات وب را رتبه‌بندی کند. یادگیری ماشین الگوریتمی ریاضی است که داده‌های ورودی را گرفته و شبیه به هر فرمول خروجی تولید می‌کند (Statt, N. 2018). براساس نوع یادگیری چهار نوع اصلی روش یادگیری ماشین داریم: "یادگیری با نظارت"، "یادگیری بدون نظارت"، "یادگیری نیمه نظارتی" و "یادگیری تقویتی".

در تکنیک یادگیری با نظارت، ماشین‌ها را با استفاده از مجموعه داده‌های "برچسب‌دار" آموزش می‌دهیم و بر اساس آموزش ماشین خروجی را پیش‌بینی می‌کنیم. می‌توان گفت ابتدا ماشین را با ورودی و خروجی مربوطه آموزش می‌دهیم و سپس از ماشین می‌خواهیم با استفاده از مجموعه داده آزمایشی، خروجی را پیش‌بینی کند. هدف اصلی تکنیک یادگیری با نظارت ترسیم متغیر ورودی (X) با متغیر خروجی (Y) است. برخی از کاربردهای واقعی یادگیری با نظارت عبارتند از: ارزیابی ریسک، تشخیص تقلب، فیلتر کردن هرزنامه ایمیل

و ...

در یادگیری بدون نظارت، مدل بدون هیچ نظارتی بر روی آن داده‌ها عمل می‌کند. هدف اصلی الگوریتم یادگیری بدون نظارت، گروه‌بندی یا دسته‌بندی مجموعه داده‌های مرتب نشده براساس شباهت‌ها، الگوها و تفاوت‌ها است. به ماشین‌ها دستور داده می‌شود که الگوهای پنهان را از مجموعه داده ورودی پیدا کنند. به عنوان مثال فرض کنید سبدهای از تصاویر میوه وجود دارد و آن را در مدل یادگیری ماشینی

وارد می‌کنیم. تصاویر کاملاً برای مدل ناشناخته هستند و وظیفه دستگاه یافتن الگوها و دسته بندی اشیا است (Heaton, J. B., Polson, N. G., & Witte, J. H. 2016).

یادگیری نیمه نظارتی نوعی الگوریتم یادگیری ماشینی است که بین یادگیری ماشینی تحت نظارت و بدون نظارت قرار دارد. از ترکیب مجموعه داده‌های برچسب‌گذاری شده و بدون برچسب در طول دوره آموزشی استفاده می‌کند. اگرچه یادگیری نیمه نظارت شده حد وسط بین یادگیری نظارت شده و بدون نظارت است و بر روی داده‌هایی که از چند برچسب تشکیل شده، عمل می‌کند، اما عمدتاً از داده‌های بدون برچسب تشکیل شده است. از آنجایی که داده‌های برچسب‌گذاری در یادگیری با نظارت گرانند، اما برای اهداف شرکتی ممکن است تعداد کمی برچسب داشته باشند. یادگیری نیمه نظارتی کاملاً متفاوت از یادگیری تحت نظارت و بدون نظارت است زیرا براساس وجود و عدم وجود برچسبها است. یادگیری تقویتی براساس یک فرآیند مبتنی بر بازخورد کار می‌کند، که در آن یک عامل هوش مصنوعی (یک جزء نرم افزاری) به طور خودکار محیط اطراف خود را با ضربه زدن و دنبال کردن، انجام عمل، یادگیری از تجربیات و بهبود عملکرد خود بررسی می‌کند. نماینده برای هر عمل خوب پاداش می‌گیرد و برای هر عمل بد مجازات می‌شود. از این رو هدف عامل یادگیری تقویتی به حداکثر رساندن پاداش است. در یادگیری تقویتی هیچ داده برچسب‌گذاری شده‌ای مانند یادگیری تحت نظارت وجود ندارد و عوامل فقط از تجربیات خود یاد می‌گیرند.

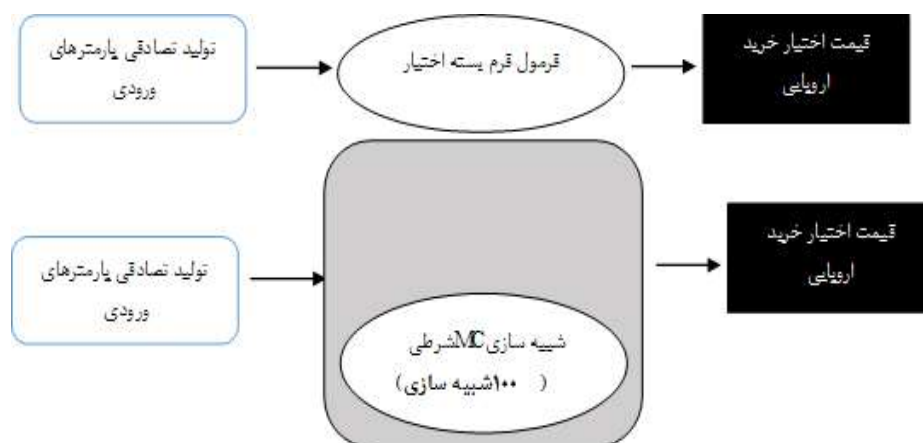
در این مقاله از یادگیری با نظارت برای آموزش مدل خود استفاده شده است. یادگیری با نظارت را می‌توان به دو شاخه "دسته بندی" و "رگرسیون" طبقه بندی کرد. که برای مدل‌های مالی روش "رگرسیون" را به کار می‌بریم. برای حل مسائل رگرسیونی که در آنها رابطه خطی بین متغیرهای ورودی و خروجی وجود دارد، استفاده می‌شود. برای پیش‌بینی متغیرهای خروجی پیوسته مانند روند بازار، استفاده می‌شوند. برخی از الگوریتم‌های رگرسیونی محبوب عبارتند از: الگوریتم رگرسیون خطی ساده، الگوریتم رگرسیون چند متغیره و الگوریتم درخت تصمیم.

در یادگیری ماشینی تقسیم داده‌ها معمولاً برای جلوگیری از برازش بیش از حد انجام می‌شود. این به این معناست که یک مدل یادگیری ماشینی با داده‌های آموزشی خود خیلی خوب مطابقت دارد، ولی نمی‌تواند به طور قابل اعتمادی داده‌های جدید را اضافه کند. داده‌های اصلی در یک مدل یادگیری ماشینی به سه مجموعه تقسیم می‌شود. سه مجموعه‌ای که معمولاً مورد استفاده قرار می‌گیرند عبارتند از مجموعه آموزشی، مجموعه توسعه دهنده و مجموعه آزمایش (Heaton, J. B., Polson, N. G., & Witte, J. H. 2016). از مفاهیم تابع خطا، تابع هزینه، الگوریتم گرادیان کاهشی، الگوریتم پس انتشار، توابع فعال ساز (ELU, Leaky ReLU, ReLU)، SoftPlus SELU و نمایی) و الگوریتم Adam در یادگیری ماشینی و شبکه‌های عصبی مصنوعی نیز برای یادگیری مدل استفاده می‌کنیم (Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Zheng, X. 2016). (Nair, V., & Hinton, G. E. 2010)، (Sakketou, F., & Ampazis, N. 2019)، (Biswas, K., Kumar,)، (S., Banerjee, S., & Pandey, A. K. 2020)، (Kingma, D. P., & Ba, J. 2014).

بررسی ایده‌ها و مدل‌های مطرح شده، تولید و تجزیه و تحلیل داده‌ها در این پژوهش با استفاده از نرم افزار آناکوندا (ژویپتر) و زبان برنامه نویسی پایتون صورت گرفته است.

مدل پیش‌گویی قیمت اختیار

در این بخش از یادگیری عمیق برای قیمت‌گذاری اختیار اروپایی تحت مدل *SVSI* از داده‌های شبیه‌سازی شده برای یادگیری مدل استفاده شده است. با استفاده از سه روش فرمول‌بسته اروپایی تحت توابع مشخصه *SVSI* در بخش ۲-۱، شبیه‌سازی مونت کارلو قیمت‌گذاری اختیار اروپایی، شبیه‌سازی مونت کارلو شرطی قیمت‌گذاری اختیار اروپایی در بخش ۲-۲ برای $\rho_{S,R} = 0$ سه مجموعه داده تولید می‌شود. برای سه مجموعه داده قیمت، از مقادیر پارامتر مورد نیاز با توجه به محدوده پارامترهای جدول ۱ استفاده شده است. سپس داده‌های تولید شده به دو مجموعه آموزش و آزمایش تقسیم گردید. با در نظر گرفتن محدوده پارامترهای اختیار در جدول ۱، مقدار زیادی داده به صورت تصادفی تولید گردید. با توجه به رابطه همگن خطی تئوری قیمت‌گذاری اختیار اروپایی (Culkin, R., & Das, S. R. 2017)، می‌توان نتیجه گرفت که قیمت اختیار C به صورت خطی با قیمت سهام S و قیمت سهام K وابسته است و بنابراین می‌توان قیمت اختیار و قیمت سهام را به قیمت اعمال تقسیم کرد. با توجه به نرمال‌سازی قیمت اختیار اروپایی، پارامترها با توجه به پارامتر K نرمال و وارد مدل یادگیری عمیق شدند. با توجه به سه روش در قیمت‌گذاری اختیار اروپایی تحت مدل *SVSI* برای $\rho_{S,R} = 0$ سه مجموعه با اندازه‌های ۱۰۰۰۰ تولید و سپس داده‌ها را به مجموعه‌های آموزشی و آزمون‌ها تقسیم نمودیم. شکل ۱ نمودار جریان فرآیند تولید داده در قیمت‌گذاری اختیار اروپایی تحت مدل *SVSI* را نشان می‌دهد. فلوچارت اول فرآیند تولید داده‌ها را برای فرمول‌بسته قیمت‌گذاری اختیار اروپایی تحت تابع مشخصه مدل *SVSI* نشان می‌دهد که در آن ابتدا پارامترها را به صورت تصادفی تولید و پارامترهای به دست آمده را در فرمول‌بسته قیمت‌گذاری اختیار اروپایی تحت تابع مشخصه یعنی قیمت اختیار اروپایی وارد می‌کنیم. فلوچارت دوم روند تولید داده‌ها را برای قیمت‌گذاری روش‌های مونت کارلو قیمت‌گذاری اختیار اروپایی با استفاده از ۱۰۰ عدد شبیه‌سازی نشان می‌دهد.



شکل ۱- فلوچارت فرآیند تولید داده قیمت‌گذاری اختیار خرید اروپایی تحت مدل *SVSI*

جدول ۱- پارامترها و دامنه‌ها

پارامتر	دامنه
قیمت سهام اولیه (S_0)	50\$ - 700\$
قیمت اعمال (K)	10\$ - 500\$
تاریخ سرسید (T)	years (1 - 10)
نرخ بهره ریسک خنثی اولیه (r_0)	1% - 10%
تلاطم اولیه (V_0)	1% - 90%
نوسان تلاطم (σ_V)	0% - 90%
نوسان نرخ بهره (σ_R)	0% - 90%
میانگین نرخ بازگشت تلاطم (k_V)	0 - 10
میانگین نرخ بازگشت نرخ بهره (k_R)	0 - 10
تلاطم بلند مدت قیمت سهام (θ_V)	0% - 90%
نرخ بهره بلند مدت قیمت سهام (θ_R)	0% - 90%
ضریب همبستگی ($\rho_{S,V}$)	-0/9 - 0/9
عامل ریسک در تلاطم (λ_V)	30 -
عامل ریسک در نرخ بهره (λ_R)	30 -

ماخذ: یافته‌های تحقیق

ساختار مدل یادگیری عمیق قیمت اختیار

در این بخش با استفاده از ۱۴ پارامتر که به عنوان داده‌های ورودی مدل تعریف می‌شوند و از مفاهیم مورد نیاز مانند تعداد لایه، تعداد نورون موجود در هر لایه، توابع فعال ساز و... در بخش ۳- برای ساخت مدل استفاده می‌کنیم. ابتدا از مجموعه داده‌های فرمول فرم بسته قیمت اختیار خرید اروپایی تحت مدل SVSI برای ساختن و پیدا کردن مدل بهینه یادگیری عمیق برای پیش‌گویی قیمت اختیار خرید اروپایی خود استفاده کرده و سپس مدل بهینه یادگیری برای سه مجموعه داده قیمت اختیار مورد آزمایش قرار می‌دهیم. مجموعه داده فرمول فرم بسته قیمت اختیار خرید اروپایی تحت مدل SVSI را به دو مجموعه آموزشی (۸۰ درصد) و مجموعه ای از آزمون‌ها (۲۰ درصد) تقسیم می‌کنیم، سپس ۲۰ درصد از داده‌های آزمون را به داده‌های اعتبارسنجی اختصاص می‌دهیم. و از مجموعه آموزش برای

ساخت مدل استفاده می‌کنیم. در جدول ۲- از ده مدل برای پیش‌گویی قیمت اختیار خود استفاده نمودیم. در این جدول اطلاعات کلی از هائیرپارامترهای مدل‌ها از جمله تعداد لایه‌ها و تعداد نورون در هر لایه و توابع فعال ساز به کار رفته شده در هر لایه آمده است.

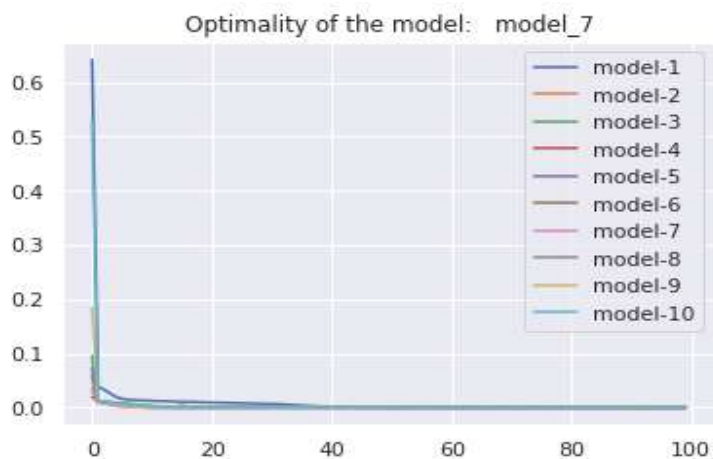
جدول ۲- مدل‌های یادگیری عمیق آزمایش شده برای پیش‌بینی قیمت اختیار اروپایی تحت مدل SVSI.

نام مدل	تعداد لایه	تعداد نورون در هر لایه (از چپ به راست)	توابع فعال ساز در هر لایه (از چپ به راست)
Model-1	3	[20,20,1]	[relu,relu,linear]
Model-2	3	[100,50,1]	[relu,relu,linear]
Model-3	4	[30,60,60,1]	[relu,relu,relu,linear]
Model-4	5	[30,60,60,30,1]	[relu,relu,relu,relu,linear]
Model-5	5	[50,100,100,50,1]	[relu,relu,relu,relu,linear]
Model-6	5	[50,100,100,50,1]	[relu,elu,relu,elu,linear]
Model-7	5	[50,100,100,50,1]	[relu,elu,relu,elu,softplus]
Model-8	5	[50,100,100,50,1]	[relu,selu,relu,selu,softplus]
Model-9	5	[50,100,100,50,1]	[LeakyReLU,selu,relu,selu,softplus]
Model-10	5	[50,100,100,50,1]	[LeakyReLU,selu,relu,selu,exp]

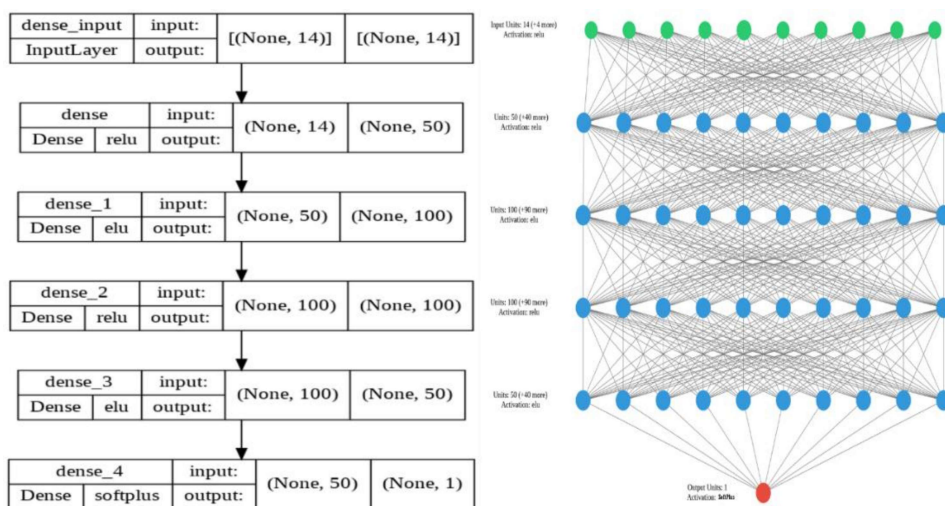
ماخذ: یافته‌های تحقیق

شکل (۲) نشان دهنده نمودار خطا در مدل‌های آزمایش شده در جدول (۲) است. که نتیجه می‌شود مدل *Model-7* مدل بهینه برای پیش‌بینی قیمت اختیار اروپایی تحت مدل *SVSI* است. با توجه به شکل (۳) جزئیات شبکه یادگیری عمیق برای قیمت‌گذاری اختیار بدین قرار است که ۱۴ پارامتر ورودی در این شبکه یادگیری عمیق وجود دارد که این پارامترها با فعال کردن توابع از طریق ۴ لایه پنهان، که هر لایه به ترتیب شامل ۵۰، ۱۰۰، ۱۰۰، ۵۰ نورون است، تنظیم می‌شود. توابع فعال کننده در هر لایه تابع فعال ساز *RELU* در لایه اول، تابع فعال ساز *ELU* در لایه دوم، تابع فعال ساز *RELU* در لایه سوم و تابع فعال ساز *ELU* در لایه چهارم به ترتیب انتخاب شده‌اند. در لایه خروجی نهایی که دارای یک نورون منحصر به فرد است، تابع فعال سازی *softplus* عملیات محاسباتی را در آن لایه انجام می‌دهد. تابع فعال ساز *softplus* به این دلیل استفاده می‌شود که قیمت اختیار نمی‌تواند یک مقدار منفی باشد. در این الگوریتم یادگیری، از تابع هزینه میانگین مربعات خطا (*MSE*) و روش بهینه‌سازی آدام (*Adam*) برای این شبکه یادگیری عمیق استفاده می‌کنیم. این مدل با استفاده از کتابخانه *Tensorflow* آموزش داده شده است. با استفاده از داده‌های تولید شده، مدلی برای

قیمت گذاری اختیار آموزش می دهیم. این فرآیند ۱۰۰ بار تکرار می شود. برای هر گروه از داده ها با تخصیص مجموعه آموزشی و مجموعه آزمون، آموزش مدل یادگیری عمیق ۱۰۰ بار با ۱۰ حالت اولیه تصادفی اعمال می شود.



شکل ۲- نمودار خطا در مدل های آزمایش شده (ماخذ: یافته های تحقیق)



شکل ۳- فلوچارت و نمودار کلی مدل یادگیری عمیق Model-7 برای پیش بینی قیمت گذاری اختیار تحت مدل SVSI.

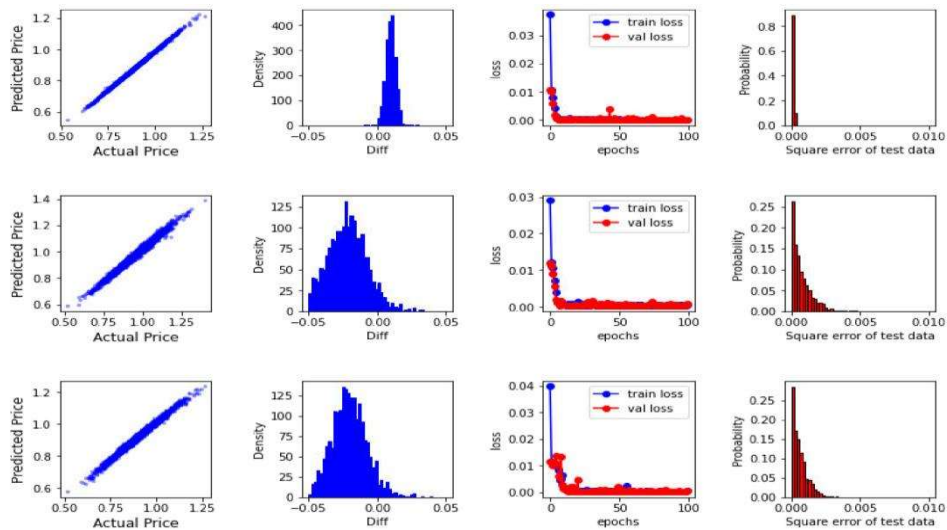
پس از انجام آزمایش های بسیار برای ساختن مدل یادگیری عمیق برای پیش گویی قیمت اختیار تحت مدل ذکر شده و با توجه به مجموعه داده فرمول فرم بسته و صریح قیمت اختیار، کارایی یادگیری عمیق به طور شهودی نشان داده می شود.

یافته های پژوهش

در نتایج شهودی چهار معیار را برای اثربخشی یادگیری عمیق گزارش می کنیم:

ستون اول قیمت های پیش بینی شده با استفاده از یادگیری عمیق را در مقابل داده های قیمت تولید شده توسط رایانه براساس سه روش در مدل *SVSI* نشان می دهد. ستون دوم، توزیع خطاهای پیش بینی مطلق برای بررسی خطاهای بین قیمت های پیش بینی شده استاندارد شده اختیار با استفاده از یادگیری عمیق و داده های قیمت تولید شده توسط سه روش در مدل *SVSI* بیان می کند. ستون سوم، منحنی میانگین مربعات خطای مدل یادگیری عمیق در مجموعه آموزش و مجموعه داده های اعتبارسنجی برای سه روش در مدل *SVSI* نشان می دهد. ستون چهارم، توزیع مربعات خطا روی مجموعه داده آزمون را نشان می دهد، که محور γ نشان دهنده احتمال نرمال خطا است. در شکل (۴)، سطر اول، دوم و سوم به ترتیب مربوط به فرآیند تولید داده از فرمول فرم بسته براساس تابع مشخصه، شبیه سازی مونت کارلو، شبیه سازی مونت کارلو شرطی برای مدل *SVSI* با توجه به پارمتر $\rho_{S,R} = 0$ است. شکل (۴) استفاده از چهار معیار برای تولید داده قیمت اختیار خرید اروپایی با بکارگیری سه روش تحت مدل *SVSI* کارایی یادگیری عمیق را نشان می دهد. با استفاد از نمودارها نتایج زیر را بدست می آوریم:

در ستون اول برای هر سه روش در مدل *SVSI* که برای مجموعه آزمون آمده است، تقریباً جفت قیمت های واقعی و پیش بینی شده به یک خط مستقیم ۴۵ درجه با عرض بسیار باریک، نزدیک هستند؛ به این معنی که قیمت های پیش بینی شده نزدیک به داده های واقعی است که در مدل یادگیری عمیق اعمال می شود. در ستون دوم، بیشتر خطاهای قیمت گذاری برای مجموعه آزمون تحت هر سه روش در مدل *SVSI*، خطا در محدوده ± 0.05 است. در ستون سوم، منحنی میانگین مربعات خطا مدل یادگیری عمیق برای مجموعه داده های آموزش و مجموعه داده های اعتبارسنجی هر سه روش تحت مدل *SVSI*، پس از ۶۰ دوره به هم نزدیک می شوند. در ستون چهارم، توزیع خطای مربعی روی مجموعه داده آزمون نشان می دهد، که احتمال بیشتر خطاها بسیار کوچک هستند. نتیجه می گیریم که مدل یادگیری عمیق برای هر سه مجموعه داده به خوبی آموزش دیده است.



شکل ۴- نتایج شهودی یادگیری عمیق برای قیمت گذاری اختیار خرید اروپایی تحت مدل SVSI با توجه به پارامتر $\rho_{S,R} = 0$. (ماخذ: یافته های تحقیق)

در نهایت کارایی روش یادگیری عمیق را بررسی می کنیم. جدول (۳) زمان محاسبه برای ۱۰۰۰ و ۱۰۰۰۰ قیمت اختیار خرید اروپایی را با چهار روش، مدل بهینه یادگیری عمیق، فرمول فرم بسته براساس تابع مشخصه، شبیه سازی مونت کارلو و شبیه سازی مونت کارلو شرطی برای مدل SVSI با توجه به پارامتر $\rho_{S,R} = 0$ مقایسه می کند. با توجه به نتایج به دست آمده در جدول (۳) محاسبه ۱۰۰۰ و ۱۰۰۰۰ قیمت اختیار با استفاده از مدل بهینه یادگیری عمیق زیر یک ثانیه صورت گرفته است. از آنجایی که افراد متخصص معمولاً باید در زمانی اندک تعداد زیادی محاسبات را انجام دهند، سرعت محاسبات در تجارت و صنعت بسیار مهم است بنابراین روش یادگیری عمیق برای قیمت گذاری اختیار نسبت به روش هایی که در گذشته مورد استفاده قرار گرفته است، موثرتر است.

جدول ۳- زمان محاسبه برای ۱۰۰۰ و ۱۰۰۰۰ قیمت اختیارهای خرید اروپایی

روش های محاسبه قیمت گذاری اختیار اروپایی				تعداد قیمت اختیار
روش مونت کارلو شرطی	روش مونت کارلو	روش فرم بسته	مدل یادگیری عمیق	
$\approx 10^6 s$	$\approx 10^5 s$	$\approx 98/14$	$\approx 0/43$	۱۰۰۰
$\approx 10^8 s$	$\approx 10^7 s$	$\approx 839/22$	$\approx 0/66$	۱۰۰۰۰

ماخذ: یافته های تحقیق

نتیجه‌گیری و پیشنهاد

یک مدل قیمت‌گذاری اختیار ساده را توسعه داده و مورد آنالیز قرار گرفت که هم نوسانات تصادفی و هم نرخ‌های بهره تصادفی را می‌پذیرد. نشان داده شد که این فرمول قیمت‌گذاری فرم بسته عملاً قابل پیاده‌سازی است و شامل بسیاری از فرمول‌های اختیار شناخته شده به عنوان موارد خاص است. مدل‌های *SVSI* نسبت به مدل‌های بلک-شولز، بسیار بهتر عمل می‌کنند و خطای قیمت‌گذاری را به نصف کاهش می‌دهند. با توجه به اینکه مدل *SVSI* را می‌توان به راحتی در رایانه شخصی پیاده‌سازی کرد، بنابراین باید جایگزین‌های بهتری برای کاربردهای گسترده فرمول *BS* باشند. به طور کلی نتایج به طور تجربی از این ادعا حمایت می‌کند که ترکیب نرخ‌های بهره تصادفی و به ویژه نوسانات تصادفی، می‌تواند هم قیمت‌گذاری اختیار را به طور اساسی بهبود بخشد و هم برخی سوگیری‌های تجربی شناخته شده مرتبط با مدل بلک-شولز را حل کند. در این پژوهش یک چارچوب شبیه‌سازی *CMC* برای مسئله قیمت‌گذاری اختیار اروپایی ایجاد شد؛ فرض بر این است که دارایی پایه از مدل نوسان تصادفی ترکیبی و مدل نرخ بهره تصادفی پیروی می‌کند. دو تقریب برای یک مارتینگل بهینه مشتق شده از قضیه بازنمایی مارتینگل پیشنهاد شد و تقریب‌ها برای متغیرهای کنترل براساس شبیه‌سازی *CMC* استفاده شد. نتایج عددی نشان می‌دهد که این روش ترکیبی دارای اثر کاهش واریانس و کارایی بسیار بالایی است. از آنجا که بازارهای مالی داده‌های زیادی را در خود جای داده است، برای این که بتوان این داده‌ها را به عنوان یک متخصص مالی، مدیریت و براساس آنها تصمیم‌گیری کرد، باید به علم یادگیری عمیق تسلط داشت. برای قیمت‌گذاری اختیار اروپایی تحت مدل *SVSI* از داده‌های شبیه‌سازی شده برای یادگیری عمیق مدل استفاده شده است. آزمایش‌های عددی نشان می‌دهند که روش یادگیری عمیق در مقایسه با روشهای فرم بسته، شبیه‌سازی *CMC*، شبیه‌سازی سنتی *MC* یا سایر روش‌های متغیر کنترل، از کارایی بالا و عملکرد پایداری برخوردار است.

منابع و مأخذ

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Zheng, X. (2016). {TensorFlow}: a system for {Large-Scale} machine learning. In 12th USENIX symposium on operating systems design and implementation (OSDI 16) (pp. 265-283).
- Andersen, T. G., & Lund, J. (1997). Estimating continuous-time stochastic volatility models of the short-term interest rate. *Journal of econometrics*, 77(2), 343-377.
- Amin, K. I., & Jarrow, R. A. (1992). Pricing options on risky assets in a stochastic interest rate economy 1. *Mathematical Finance*, 2(4), 217-237.
- Bailey, W., & Stulz, R. M. (1989). The pricing of stock index options in a general equilibrium model. *Journal of Financial and Quantitative Analysis*, 24(1), 1-12.
- Bakshi, G., Cao, C., & Chen, Z. (2010). Option pricing and hedging performance under stochastic volatility and stochastic interest rates. *Handbook of quantitative finance and risk management*, 547-574.
- Bakshi, G. S., & Chen, Z. (1997). An alternative valuation model for contingent claims. *Journal of Financial Economics*, 44(1), 123-165.
- Betes, D. (1996). Testing option pricing models, in "Statistical Methods in Finance" (eds. GS Maddala and CR Rao), *Handbook of Statistics*, 14.
- Biswas, K., Kumar, S., Banerjee, S., & Pandey, A. K. (2020). TanhSoft--a family of activation functions combining Tanh and Softplus. arXiv preprint arXiv:2009.03863.

- Black, F., & Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of political economy*, 81(3), 637-654.
- Boyle, P. P. (1977). Options: A monte carlo approach. *Journal of financial economics*, 4(3), 323-338.
- Chan, K. C., Karolyi, G. A., Longstaff, F. A., & Sanders, A. B. (1992). An empirical comparison of alternative models of the short-term interest rate. *The journal of finance*, 47(3), 1209-1227.
- Choe, G. H. (2016). *Stochastic analysis for finance with simulations* (pp. 583-558). Berlin: Springer.
- Cox, J. C., & Ross, S. A. (1976). The valuation of options for alternative stochastic processes. *Journal of financial economics*, 3(1-2), 145-166
- Culkin, R., & Das, S. R. (2017). Machine learning in finance: the case of deep learning for option pricing. *Journal of Investment Management*, 15(4), 92-100.
- Ferguson, R., & Green, A. (2018). Deeply learning derivatives. arXiv preprint arXiv:1809.02233.
- Gan, L., Wang, H., & Yang, Z. (2020). Machine learning solutions to challenges in finance: An application to the pricing of financial products. *Technological Forecasting and Social Change*, 153, 119928.
- Glasserman, P. (2004). *Monte Carlo methods in financial engineering* (Vol. 53, pp. xiv+-596). New York: springer.
- Hansen, L. P. (1982). Large sample properties of generalized method of moments estimators. *Econometrica: Journal of the econometric society*, 1029-1054.
- Harrison, J. M., & Kreps, D. M. (1979). Martingales and arbitrage in multiperiod securities markets. *Journal of Economic theory*, 20(3), 381-408.
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2016). Deep learning in finance. arXiv preprint arXiv:1602.06561.
- Heston, S. L. (1993). A closed-form solution for options with stochastic volatility with applications to bond and currency options. *The review of financial studies*, 6(2), 327-343.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
- Liang, Y., & Xu, C. (2020). An efficient conditional Monte Carlo method for European option pricing with stochastic volatility and stochastic interest rate. *International Journal of Computer Mathematics*, 97(3), 638-655.
- Metropolis, N., & Ulam, S. (1949). The monte carlo method. *Journal of the American statistical association*, 44(247), 335-341.
- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).
- Sakketou, F., & Ampazis, N. (2019). On the invariance of the selu activation function on algorithm and hyperparameter selection in neural network recommenders. In *Artificial Intelligence Applications and Innovations: 15th IFIP WG 12.5 International Conference, AIAI 2019, Hersonissos, Crete, Greece, May 24–26, 2019, Proceedings 15* (pp. 673-685). Springer International Publishing.

Scott, L. O. (1997). Pricing stock options in a jump-diffusion model with stochastic volatility and interest rates: Applications of Fourier inversion methods. *Mathematical Finance*, 7(4), 413-426.

Statt, N. (2018). The AI boom is happening all over the world, and it's accelerating quickly. *The Verge*.

The effect of organizational hypocrisy on deviant behaviors in the workplace through organizational identity and organizational social responsibility (Study case: Isfahan Islamic Azad University (Khorasgan))

Abbas Ghaeidamini¹, Reza Ebramizade Dastjerdi² and Mehrdad Sadeghi³

Abstract

The purpose of this research was to investigate the effect of organizational hypocrisy on deviant behaviors in the workplace through organizational identity and organizational social responsibility. The present study was applied in terms of its purpose and descriptive in terms of correlational data collection. The statistical population of the present study consisted of all the employees of Isfahan branch of Islamic Azad University (Khorasgan) in the number of 660 people, and 244 people were selected as a sample through the proportional stratified sampling method through the Cochran sampling formula. The research tools are organizational social responsibility questionnaire by Farouk et al. (2014), questionnaire of deviant behaviors in the workplace by Bennett and Robinson (2000) and standard questionnaire of organizational hypocrisy by Kulichoglu et al. (2019) and organizational identity questionnaire by Ant et al. 2006) that the validity of the questionnaires was examined based on content, form and structure validity and after the necessary terms, the validity was confirmed. And on the other hand, the reliability Questionnaires were estimated by Cronbach's alpha method as 0.90, 0.88, 0.90 and 0.89 respectively. Data analysis was done at two descriptive and inferential levels including structural equation modeling. The results of the research showed that the direct effect of organizational hypocrisy on deviant behavior in the workplace was significant and positive, and the coefficient of this effect was 0.77, Also, the results showed that organizational identity and organizational social responsibility mediated the relationship between organizational hypocrisy and deviant behaviors in the workplace.

Keywords: organizational hypocrisy, deviant behaviors in the workplace, organizational identity, organizational social responsibility

¹Phd Student of Cultural Management and Planning, Department of Management, Lahijan Branch, Islamic Azad University, south Tehran Branch, Tehran, Iran. Email Address: abbasghaedamini2020@gmail.com

²Corresponding Author, Assistant Professor, Department of Management, Isfahan(Khorasgan) Branch, Islamic Azad University, Isfahan, Iran. Email Address: ag7220500@gmail.com

³Assistant Professor, Department of Management, Isfahan(Khorasgan) Branch, Islamic Azad University, Isfahan, Iran.