

این فایل ویراستاری نشده و جهت مشاهده متن کامل مقاله است.
جهت استناد استفاده نشود، فایل ویراستاری شده در نوبت انتشار
مقاله در دسترس قرار خواهد گرفت

نشده، غیر قابل انتشار

کاربرد الگوریتم‌های یادگیری ماشین کوانتومی در علوم مالی

محمد مهدی لطفی هروی^۱، منیره هوشمند^۲، مرضیه اسعدی^۳

چکیده

یادگیری ماشین، مجموعه‌ای از الگوریتم‌ها است که این امکان را برای کامپیوتر ایجاد می‌کند که الگوهای آماری و رفتاری در داده‌ها را بدون برنامه‌نویسی صریح بیاموزد. این الگوریتم‌ها کاربردهای گسترده‌ای در همه زمینه‌ها بویژه علوم مالی که نیاز به توان و دقت محاسباتی بالا دارند شامل مدل‌سازی بازارهای مالی، مدیریت سبد دارایی‌ها، ریسک‌سنجی و غیره دارد. اما از آنجا که اغلب این روش‌ها نیاز به حجم زیادی از داده دارد، انجام این محاسبات بر روی کامپیوترهای کلاسیک به میزان زیادی زمان و منابع محاسباتی نیاز دارد که ممکن است در عمل از کارایی‌های فنی و تخصیصی برخوردار نباشند. در این راستا کامپیوترهای کوانتومی به علت قدرت پردازش موازی می‌توانند مسائل را بسیار سریع‌تر از الگوریتم‌های هم‌نامی کلاسیک خود حل کنند که سبب افزایش سرعت کوانتومی در الگوریتم‌های یادگیری ماشین خواهد شد. این مقاله به بررسی کاربرد محاسبات کوانتومی در حل مسائل علوم مالی پرداخته و با روش‌های کلاسیک موجود مقایسه می‌کند. روش‌شناسی پژوهش مطالعه اسنادی و کتابخانه‌ای است که در این راستا مقاله مسائل مهم محاسباتی در اقتصاد مالی را مطرح نموده و سپس به معرفی الگوریتم‌های بهینه‌سازی کوانتومی برای حل مسائل پرداخته است. بطور مشخص پژوهش حاضر تلاش کرده است که آن دسته از مسائل محاسباتی در حوزه علوم مالی که استفاده از روش یادگیری ماشین کوانتومی نسبت به بهترین الگوریتم‌های کلاسیک متناظر برتری ایجاد می‌کند را شناسایی نماید. همچنین امکان‌پذیری تحقق فیزیکی این روش‌ها در کوتاه مدت نیز بررسی شده است. نتایج این مطالعه نشان می‌دهد که چگونه روش‌های محاسبات کوانتومی می‌تواند منجر به افزایش سرعت و دقت در تحلیل‌ها و پیش‌بینی‌های اقتصاد مالی شده و جایگزین بهتری برای روش‌های کلاسیک به ویژه در مدیریت سبد دارایی و تحلیل ریسک است.

واژگان کلیدی: یادگیری ماشین، علوم مالی، محاسبات کوانتومی، یادگیری عمیق، یادگیری تقویتی

طبقه بندی JEL: G۰۰، C۶۰، C۴۰.

Application of Quantum Machine Learning Algorithms in Financial Sciences

۱. استادیار اقتصاد گروه اقتصاد و مالی، دانشکده مدیریت، علم و فناوری، دانشگاه صنعتی امیرکبیر (نویسنده مسئول)؛

mahdi.lotfi@aut.ac.ir

۲. دانشیار گروه مهندسی برق، دانشگاه بین‌المللی امام رضا (ع)؛ m.hooshmand@imamreza.ac.ir

۳. استادیار گروه مدیریت و اقتصاد، دانشکده علوم انسانی و اجتماعی، دانشگاه گلستان؛ m.asaadi@gu.ac.ir

Abstract

Machine learning is a set of algorithms that make it possible for a computer to learn the statistical and behavioral patterns in data without explicit programming. These algorithms have wide applications in all fields, especially financial sciences, which require high computational power and accuracy, including financial market modeling, portfolio management, risk assessment, etc. But because most of these methods require large amounts of data, performing these calculations on classical computers requires a large amount of computational time and resources that may not be technically and allocatively efficient in practice. In contrast, quantum computers, due to their parallel processing power, can solve problems much faster than their classical counterpart algorithms, which will increase the quantum speed of machine learning algorithms. This article examines the application of quantum computing in solving financial science problems and compares it with existing classical methods. The applied research methodology is a documentary and library study in which the paper raises important computational issues in financial economics and then introduces quantum optimization algorithms to solve problems. Specifically, the present study has tried to identify those computational problems in the field of financial sciences that the use of quantum machine learning method is superior to the best classical corresponding algorithms. The feasibility of physical realization of these methods in the short term has also been investigated. The results of this study show how quantum computing methods can increase the speed and accuracy of financial economics analysis and forecasting and is a better alternative to classical methods, especially in portfolio management and risk analysis.

Key words: Machine Learning, Financial Sciences, Quantum Computing, Deep Learning, Reinforcement Learning.

JEL Classification: C۴۰, C۶۰, G۰۰.

مقدمه

نیاز روزافزون بشر به پردازش اطلاعات با سرعت بالاتر منجر به ساخت تراشه‌های سریع‌تر و پیچیده‌تر شده است. برای ایجاد این تراشه‌ها، لازم است که تعداد ترانزیستورهای بیشتری بر روی تراشه تعبیه شود. طبق قانون مور، تعداد ترانزیستورهای روی یک تراشه (با مساحت ثابت) تقریباً هر دو سال، دو برابر خواهد شد. این رشد نمایی که در سال ۱۹۶۵ پیش‌بینی شده بود تاکنون ادامه داشته است. اما با کوچکتر شدن ابعاد و رسیدن به ابعاد

^۱. Assistant Professor of Economics, Department of Management, Science and Technology, Amirkabir University of Technology (Corresponding author); mahdi.lotfi@aut.ac.ir

^۲. Associated Professor of Associate Professor, Department of Electrical Engineering, Imam Reza International University

^۳. Assistant Professor of Economics, Department of Management and Economics, Faculty of Humanities and Social Sciences, Golestan University

اتمی، چالشی که رخ می‌دهد این است که در ابعاد اتمی، قوانین فیزیکی که بر رفتار ذرات حاکم هستند، قوانین مکانیک کوانتومی هستند و نه قوانین مکانیک کلاسیک (Marinescu and Marinescu, ۲۰۰۴). در این صورت پیش‌بینی‌های کلاسیک، در اثر رفتار کوانتومی ذرات، نامعتبر خواهند شد. مانع دیگر در دستیابی به کاهش نمایی اندازه ترانزیستور، موانع اقتصادی می‌باشد. طبق قانون دوم مور، هزینه ساخت تراشه‌ها نیز با زمان رشد نمایی خواهد داشت (Spiller et al., ۲۰۰۵).

بنابراین بسیاری از متخصصان در زمینه‌های مختلف پیشاپیش به فکر رفع این مشکل افتادند. یکی از مهم‌ترین راه‌حلهای، تغییر جهت تمرکز محاسبات از قوانین کلاسیک کنونی به دنیای جدید کوانتومی بوده است که نه تنها مشکلات گذشته و محدودیت‌های موجود را برطرف می‌سازد، بلکه افق‌های جدیدی را نیز به دنیای محاسبات اضافه می‌کند (Meter and Oskin, ۲۰۰۶). در واقع، هدف محاسبات کوانتومی یافتن روش‌هایی برای طراحی مجدد قطعات به گونه‌ای است که بتوانند تحت آثار کوانتومی، که در محدوده ابعاد نانومتری و کوچک‌تر بروز می‌کنند، به خوبی کار کنند (Home et al., ۲۰۰۶) (Blackstad and Ospelkaus, ۲۰۰۹). به دنبال کشف الگوریتم‌های کوانتومی که قادر هستند مسائل محاسباتی سنگین را بسیار سریع‌تر از الگوریتم‌های کلاسیک حل کنند، توجه ویژه‌ی دانشگاه‌ها و سرمایه‌گذاری‌های کلان صنایع به این زمینه نوظهور جلب شده است. نمونه‌هایی از این الگوریتم‌ها، تجزیه سریع اعداد بزرگ و جستجوی سریع در یک مجموعه تصادفی می‌باشد (Mousavi et al., ۲۰۲۱).

فناوری‌های کوانتومی نسبت به روش‌های مشابه کلاسیکی خود ویژگی‌های منحصر به فردی دارند که امکان دسترسی به آن‌ها در دنیای کلاسیک غیرممکن است. به همین علت است که فناوری‌های کوانتومی به شدت مورد توجه دانشمندان و دولت‌ها قرار گرفته و سرمایه‌گذاری‌های عظیمی در این حوزه انجام شده است. برای مثال کامپیوترهای کوانتومی می‌توانند قدرت پردازش بسیار بالایی نسبت به قدرتمندترین ابرکامپیوترهای کلاسیک داشته و قادر هستند برخی مسائل ریاضی پیچیده که عملاً برای کامپیوترهای کلاسیک غیرقابل حل هستند را در زمان کوتاهی حل کنند. در حقیقت توان پردازش یک کامپیوتر کوانتومی حتی کوچک مقیاس، بیش از توانمندترین ابرکامپیوتر کلاسیکی است (Arute et al., ۲۰۱۹).

از سوی دیگر و به موازات پیشرفت‌های مرتبط با فناوریهای ماشین‌های کوانتومی، روش‌های مرتبط با محاسبات نیز از پیشرفت فزاینده‌ای برخوردار بوده‌اند. از مهم‌ترین این روش‌های محاسبات، یادگیری ماشین است که شاخه‌ای از هوش مصنوعی بوده و از داده‌ها می‌آموزد (Lpaydin, ۲۰۲۰). هدف یادگیری ماشین این است که کامپیوتر بتواند وظیفه مشخصی را انجام دهد بدون اینکه دستورالعمل‌های صریحی از کاربر بیرونی داشته باشد. الگوریتم‌های یادگیری ماشین کاربردهای روزافزونی در حوزه‌های مختلف از جمله تشخیص تصویر و گفتار، حمل و نقل، دانش مالی و اقتصادی دارد. اما چالش اصلی استفاده از روش‌های یادگیری ماشین، زمان محاسباتی و امکانات پشتیبانی مرتبط با حافظه کامپیوتر است زیرا در اغلب موارد پردازش این حجم و تنوع بالا از داده‌ها و اطلاعات به زمان و حافظه زیادی نیاز دارند (Zhang and Qiang, ۲۰۲۰).

از آنجا که کامپیوترهای کوانتومی این توانایی را دارند که مسائل را بسیار سریع‌تر از بهترین الگوریتم‌های کلاسیک موجود حل کنند، تاثیر زیادی بر بسیاری از علوم داشته و فرصت مناسبی برای حل معضل پردازش داده‌های بزرگ^۱ در حوزه‌های مختلف را فراهم کرده‌اند. اما کامپیوترهای کوانتومی صرفاً پردازنده‌های سریع‌تری نیستند که بتوان به سادگی جایگزین کامپیوترهای کلاسیک برای سرعت‌بخشی در حل مسائل نمود. بنابراین یک سوال الگوریتمی مهم بایستی برای هر کاربرد خاص پاسخ داده شود: آیا این کاربرد می‌تواند به سرعت کوانتومی برسد؟ اگر بتوان ثابت کرد که سرعت‌بخشی کوانتومی برای مساله خاصی وجود دارد، سوال بعدی این است چه زمانی این افزایش سرعت عملی خواهد شد. برای تعیین اینکه چه زمانی افزایش سرعت کوانتومی برای حوزه خاصی محقق خواهد شد، درک عمیق از الگوریتم‌های کوانتومی، منابع مورد نیاز برای اجرای آن الگوریتم، میزانی که این منابع با بازنگری الگوریتم‌ها می‌توانند کاهش یابند و همینطور سیر زمانی پیشرفت سخت‌افزار کوانتومی ضروری است. الگوریتم‌های یادگیری ماشین کوانتومی یکی از کاربردهای کامپیوتر کوانتومی است که روز به روز در حال گسترش است. طی دهه اخیر الگوریتم‌های یادگیری ماشین کوانتومی بسیاری پیشنهاد شده‌اند که افزایش سرعت قابل توجهی (نمایی و یا چند جمله‌ای) نسبت به نمونه‌های متناظر کلاسیک خود داشته‌اند (Zhang and Qiang, ۲۰۲۰).

یکی از مهم‌ترین و پرکاربردترین پیشرفت‌های محاسبات کوانتومی معطوف به علوم مالی بوده است. روند تکاملی محاسبات دیجیتال کلاسیک از دهه ۱۹۵۰ میلادی آغاز و به علت توان بالای محاسباتی جایگاه محوری پیدا کرد. سپس از دهه ۱۹۸۰ تا کنون، ایده امکان‌پذیری محاسبات عددی با استفاده از قوانین مکانیک کوانتوم برای حل محاسبات پیچیده دنبال شده است که نسبت به روشهای پردازش کلاسیک اطلاعات، محاسبات کوانتومی بر پایه الگوریتم‌های کارآمد فنی و تخصیصی با دقت و سرعت نهایی می‌باشد (Nielsen and Chuang, ۲۰۱۰). اگرچه در حال حاضر فقط پردازنده‌های کوانتومی کوچک در دسترس هستند، اما به علت انتظارات بالا برای گسترش این فناوری در آینده نزدیک، می‌توان انتظار داشت که تغییر رویکرد جدی در روشهای محاسبات و بویژه حوزه‌های اقتصاد مالی اتفاق خواهد افتاد. در این راستا اگر علوم مالی را به صورت علوم مرتبط با مدیریت فعالیت‌های اقتصادی و پول تعریف کرد، اهمیت دقت و سرعت در پردازش و حل مسائل مالی مانند پیش‌بینی بازار سهام، بهینه‌سازی پرتفولیو و سبد داراییها و مباحث مرتبط با قیمت‌گذاری و آربیتراژ مشخص شده و ایده بکارگیری روشهای محاسبه کوانتومی در اقتصاد مالی تضمین‌کننده دقت و سرعت محاسبات و تصمیم‌گیریهای مالی خواهد بود (Orús et al., ۲۰۱۹) (Hull et al., ۲۰۲۱). بررسی مطالعات در حوزه اقتصاد مالی تایید می‌کند که برخی از مسائل مالی شناخته شده را می‌توان در چارچوب نظریه‌های کوانتومی تصریح نمود (Stamatopoulos et al., ۲۰۲۰). (Mosteanu and Faccia, ۲۰۲۱) برای مثال، رابطه بلک-اسکولز-مرتون^۲ را می‌توان بر اساس معادله شرودینگر^۳ که در قوانین کوانتوم شناخته شده است نوشت و یا مدل سازی روابط آربیتراژ که در چارچوب قوانین

۲. Big Data
 ۱. Black-Scholes-Merton Formula
 ۲. Schrodinger Equation

محاسبات کوانتوم به راحتی فرمول‌بندی و حل می‌شود. بنابراین در این چارچوب می‌توان کل بازار مالی را به صورت فرآیند کوانتومی مدل و پردازش کرد (Kwangwon et al., ۲۰۱۸). (Ding et al., ۲۰۱۹)

علوم مالی نوین، حاوی حجم زیادی از مسائل محاسباتی چالشی است که توان کامپیوترهای کوانتومی می‌تواند در حل آنها موثر واقع گردد (Sergio et al., ۲۰۲۰). به عنوان مثال، سوالهای بسیاری در این حوزه می‌توانند به صورت مساله بهینه‌سازی مدل شوند. اینها مسائلی هستند که در کامپیوترهای کلاسیک به سختی حل می‌شوند، اما به کمک روش‌های بهینه‌سازی کوانتومی به سرعت قابل حل هستند. در سالهای اخیر، این حوزه به علت دسترسی تجاری ماشین‌های بهینه‌سازی کوانتومی (انیلرهای کوانتومی) کاربرد بسیار زیادی یافته‌است (Itay and Spedalieri, ۲۰۱۶).

روش دیگر در حل مسائل مالی، جستجو برای یافتن الگوها و الگوریتم‌های داده‌ها است. این روش یکی از پرکاربردترین روش‌های پیش‌بینی‌های علوم بازرگانی و مالی است که اغلب مبتنی بر روشهای داده کاوی^۲ و یادگیری ماشین بوده و تا حد زیادی دقت پیش‌بینی را افزایش می‌دهد. اما این روش‌ها اغلب مستلزم صرف هزینه و زمان محاسبات زیاد است. همچنین تحلیل‌گران محاسباتی علوم مالی، با چالش‌های مختلفی در اجرای الگوریتم‌های یادگیری ماشین در کامپیوترهای کلاسیک روبرو هستند (Alcazar et al., ۲۰۲۰). مسائل متداول شامل ارزیابی ریسک^۳ و قیمت‌گذاری مشتقات مالی پیچیده^۴ با استفاده از روشهای شبیه‌سازی مونت کارلو^۵، مدل‌سازی بازارهای مالی با معادلات دیفرانسیل تصادفی^۶، بهینه‌سازی تخصیص اوراق بهادار^۷ و شناسایی روند بازار^۸ با روش‌های یادگیری ماشین هستند (Dixon et al., ۲۰۲۰). حل این مسائل اغلب نیازمند روش‌های محاسباتی پیچیده و همچنین منابع مالی قابل توجه است. با توجه به اینکه علوم مالی نوین، شامل انبوهی از مسائل محاسباتی چالشی است که به توان کامپیوترهای کوانتومی نیاز دارند بنابراین در سالهای اخیر تلاش موثری برای توسعه الگوریتم‌های یادگیری ماشین کوانتومی انجام شده است که نیازهای داده‌های روزافزون در حوزه علوم مالی را می‌تواند برآورده کند (Biamonte et al., ۲۰۱۷).

پژوهش حاضر تلاش دارد که توضیح دهد کامپیوترهای کوانتومی چگونه بر محاسبات علوم مالی بر مبنای روش‌های یادگیری ماشین تاثیر گذاشته و خواهد گذاشت؟ همچنین در کدام گروه از این مسائل، توان محاسبات کوانتومی سرعت محاسبات را افزایش می‌دهد؟ در نهایت کدام یک از این افزایش سرعت‌ها قابلیت پیاده‌سازی عملی را در کوتاه مدت خواهند داشت؟ به منظور پاسخ به این سوالات این مقاله، حوزه‌های مختلف دانش مالی که می‌توانند از افزایش سرعت محاسباتی ایجادشده در روش‌های یادگیری ماشین کوانتومی بهره‌گیرند را بررسی کرده است.

۳. Annealer

۱. Data Mining
۲. Risk Evaluation
۳. Pricing Exotic Financial Derivatives
۴. Monte Carlo Simulation
۵. Stochastic Differential Equations
۶. Portfolio Allocation Optimization
۷. Market Trend

ساختار مقاله به این صورت تنظیم شده است. بعد از مقدمه حاضر و در بخش دوم مقاله به مرور مبانی نظری محاسبات کوانتومی و همچنین پیشرفت‌های عملی در این حوزه پرداخته شده است. سپس در بخش سوم، روش‌های یادگیری ماشین که در علوم مالی کاربرد دارند تبیین شده و الگوریتم‌های کوانتومی متناظر و میزان برتری آنها نسبت به الگوریتم‌های کلاسیک بررسی شده است. در بخش سوم همچنین در خصوص امکان پذیری عملیاتی این الگوریتمها بحث شده است. بخش چهارم به نتیجه‌گیری مقاله اختصاص یافته است.

۱- مبانی نظری محاسبات کوانتومی

این بخش ابتدا به مرور مبانی نظری محاسبات کوانتومی پرداخته و سپس سخت‌افزارهای کوانتومی موجود را بررسی کرده است.

۱-۱- نگاهی به اصول نظری محاسبات کوانتومی

محاسبات کوانتومی به معنی به کارگیری قوانین مکانیک کوانتومی برای انجام محاسبات بوده، که با روش‌های دنیای کلاسیک بسیار متفاوت است. قدرت کامپیوترهای کوانتومی در این است که براساس منطقی کار می‌کنند که دیگر مبتنی بر منطق دو ارزشی صفر و یک به معنای متداول روشن-خاموش یا غلط-درست نیستند. واحد اطلاعات در کامپیوترهای کوانتومی کوانتوم بیت و مختصراً کیوبیت^۱ نامیده می‌شود. کیوبیت‌ها دارای دو ویژگی مهم و متفاوت از دنیای کلاسیک شامل برهم‌نهی^۲ و درهم‌تنیدگی^۳ هستند. بر خلاف بیت‌های کلاسیک که در هر لحظه از زمان در وضعیت صفر و یا یک هستند، کیوبیت‌ها براساس قوانین فیزیک کوانتوم، می‌توانند همزمان صفر و یک را نیز اختیار کنند که این ویژگی برهم‌نهی کوانتومی نامیده می‌شود. به عبارت دیگر یک ثابت n کیوبیتی می‌تواند در هر لحظه از زمان، 2^n حالت را اختیار کند که منجر به قدرت محاسبات موازی در کامپیوترهای کوانتومی می‌شود (Marinescu and Marinescu, ۲۰۰۴).

ویژگی دوم بیان می‌کند که در حالت وجود دو یا بیش از دو کیوبیت، این کیوبیت‌ها می‌توانند مستقل از فاصله فیزیکی به یکدیگر وابسته باشند. این وابستگی درهم‌تنیدگی کوانتومی نامیده می‌شود. به عبارت دیگر، دو کیوبیت در صورتی درهم‌تنیده تلقی می‌شوند که بیان حالت یکی از آنها بدون داشتن حالت دیگری امکان‌پذیر نباشد و تغییر حالت یکی از آنها منجر به تغییر حالت آنی سایر کیوبیت‌ها شود. ویژگی‌های برهم‌نهی و درهم‌تنیدگی کوانتومی، محاسبات کوانتومی را به طور چشمگیری از محاسبات کلاسیک متمایز می‌کند (Marinescu and Marinescu, ۲۰۰۴).

۱-۲- سخت افزار کوانتومی موجود

۱. Qubit
۲. Superposition
۳. Entanglement

سخت افزار کامپیوترهای کوانتومی را می توان به دو دسته اصلی تقسیم کرد: دسته اول، کامپیوترهای کوانتومی هستند که مشابه کامپیوترهای کلاسیک فعلی مبتنی بر مدل گیتی و مداری رفتار می کنند (Marinescu and Marinescu, ۲۰۰۴). شرکت های اصلی که پردازنده های همه منظوره با این سبک کوانتومی تولید می کنند شامل گوگل، علی بابا، IBM، و مایکرو سافت هستند. در حال حاضر، در ساختار گیتی، گوگل دارای رکورد پردازنده کوانتومی با ۷۲ کیوبیت است (Itay and Spedalieri, ۲۰۱۶).

دسته دوم، آنیلرهای کوانتومی هستند که صرفاً برای یافتن مینیمم جهانی مساله هدف طراحی شده اند. تاکنون چندین آنیلر کوانتومی تجاری شده اند که مهم ترین آنها پردازنده DWAVE با بیش از ۲۰۰۰ کیوبیت ابرسانا است (Hu et al., ۲۰۱۹). این ماشین در آزمایشگاه ها و شرکت هایی در سراسر دنیا از قبیل گوگل و Texas A&M آزمایش شده است. نمونه های کوچک تر در استارت آپ ها نیز ساخته شده اند. در شرایط ایده آل، این کامپیوترها از توانی برابر با کامپیوترهای با مدل مداری برخوردار هستند.^۱

برتری رایانش کوانتومی بر رایانش کلاسیک با نمونه های کوچک مقیاس کامپیوترهای کوانتومی کنونی نیز اثبات شده است. به عنوان مثال در سال ۲۰۱۹، گوگل با کامپیوتر کوانتومی ۵۳ کیوبیتی خود توانست مسئله نمونه برداری تصادفی را در ۲۰۰ ثانیه حل کند. حل این مسئله با ابرکامپیوترهای کلاسیک تقریباً به ۱۰۰۰۰ سال زمان نیاز دارد (Arute et al., ۲۰۱۹).

شایان ذکر است که در حال حاضر این امکان برای همه افراد وجود دارد که به کامپیوتر کوانتومی در ابر عمومی^۲ دسترسی پیدا کرده و آزمایش های برنامه نویسی را انجام دهد. کامپیوتر کوانتومی IBM موجود در ابر (IBM Q) در حال حاضر جامعه ای با بیش از ۶۰۰۰۰ کاربر را شامل می شود که تاکنون بیش از ۱/۷ میلیون آزمایش محاسباتی با استفاده از آن انجام داده اند. این در حالی است که اولین سطح IBM Q که در دسترس عموم بود، فقط از قدرت متوسط ۵ کیوبیت برخوردار بود. پس از آن، این توان به ۱۷ و سپس ۲۰ کیوبیت ارتقا داده شده است. اخیراً IBM اعلام کرده است که قدرت پردازش نمونه اولیه پردازشگر را به ۵۰ کیوبیت توسعه داده است (Martin et al., ۲۰۲۱).

۲- یادگیری ماشین کوانتومی و کاربردهای آن در اقتصاد مالی

این بخش ابتدا الگوریتم های یادگیری ماشین کوانتومی که دارای برتری نسبت به الگوریتم های متناظر کلاسیک خود هستند را تبیین نموده و سپس کاربرد هر کدام در حوزه مالی شرح داده شده است.

در حالت کلی، کاربردهای الگوریتم های یادگیری ماشین را می توان به سه دسته (۱) پیش بینی آینده بر مبنای روند داده های گذشته (۲) دسته بندی اطلاعات و (۳) یافتن الگوها بر مبنای نظم و بی نظمی های موجود در داده ها تقسیم بندی کرد. در علوم مالی، این روش ها در بسیاری مسائل این حوزه که با عدم قطعیت در آینده سروکار

۱. برای مطالعه جزئیات بیشتر در مورد سخت افزارهای کوانتومی به این مقاله مراجعه شود:

(Chong et al., ۲۰۱۷)

۱. Public Cloud

دارند مانند ریسک و قیمت کالاها^۱ کاربرد دارند. به همین علت روشهای یادگیری ماشین بطور فراگیر در این حوزه در حال گسترش است. برای مثال کمپانی IDC^۲ سرمایه‌گذاری در حوزه یادگیری ماشین به ارزش ۵۰/۱ میلیارد دلار را در سال ۲۰۲۰ اعلام کرده است که انتظار می‌رود در هر چهار سال این رقم حداقل چهار برابر شود (Lessmann et al., ۲۰۱۵).

الگوریتم‌های یادگیری ماشین را می‌توان به دسته‌های یادگیری نظارت‌شده^۳، یادگیری نظارت‌نشده^۴، یادگیری عمیق^۵ و یادگیری تقویتی^۶ تقسیم کرد. کاربردهای اصلی یادگیری ماشین، شامل طبقه‌بندی^۷ و رگرسیون^۸ (در یادگیری نظارت‌شده)، خوشه‌بندی^۹ و استخراج ویژگی^{۱۰} (در یادگیری نظارت‌نشده) می‌باشند. شایان ذکر است که زیرروال‌های^{۱۱} جبر خطی استفاده‌های وسیعی در الگوریتم‌های یادگیری ماشین داشته و توسعه الگوریتم‌های کوانتومی جبر خطی تاثیر زیادی در گسترش حوزه یادگیری ماشین کوانتومی داشته است زیرا افزایش نمایی سرعت حل مسائل جبر خطی بر روی کامپیوترهای کوانتومی برای انواع خاصی از ماتریس‌ها را فراهم نموده است (Harrow et al., ۲۰۰۹) (Gilyén et al., ۲۰۱۸).

در اغلب کاربردهای یادگیری ماشین کوانتومی، از چند واحد پایه بهره گرفته می‌شود. برای مثال مدارهای کوانتومی برای ضرب ماتریسی، معکوس‌گیری و تصویرسازی^{۱۲} در زیرفضاهای ماتریسی در روش‌های کاهش ابعاد استفاده می‌شوند (Haener et al., ۲۰۱۸). علاوه بر این، توانایی تخمین فاصله کوانتومی بین دو بردار، برای مثال از طریق تست جابجایی^{۱۳} در روش‌های یادگیری ماشین نظارت‌شده و بدون نظارت استفاده می‌شوند (Fanizza et al., ۲۰۲۰). تست جابجایی تستی است که شباهت بین دو حالت کوانتومی را می‌سنجد. اغلب این زیرروال‌های کوانتومی نیاز به دسترسی به داده دارند که با ذخیره داده در ساختارهای خاص در حافظه با دسترسی تصادفی کوانتومی^{۱۴} محقق می‌شود. تعدادی از الگوریتم‌های کوانتومی یادگیری ماشین بر مبنای ایده کدگذاری دامنه عمل می‌کنند به این معنا که دامنه‌های حالت کوانتومی با ورودی‌های و خروجی‌های محاسبات نگاشت می‌شوند. از آنجا که حالت کوانتومی با n کیوبیت، با 2^n مقدار مختلط توصیف می‌شود این کدگذاری می‌تواند به فشرده‌گی نمایی اطلاعات منجر شود (Carrasquilla, ۲۰۲۰). در بسیاری موارد و اندازه‌های نمونه‌ای، الگوریتم‌های یادگیری ماشین کوانتومی می‌توانند میلیون‌ها بار سریعتر از همتای کلاسیک خود اجرا شوند. کاربردهای افزایش سرعت الگوریتم‌های یادگیری ماشین کوانتومی در علوم مالی در ادامه تحلیل و مزیت هر روش در پایان این بخش در جدول (۱) مقایسه و ارزیابی شده است.

-
۲. Asset Prices and Risk
 ۳. International Data Corporation
 ۱. Supervised Learning
 ۲. Unsupervised Learning
 ۳. Deep Learning
 ۴. Reinforcement Learning
 ۵. Classification
 ۶. Regression
 ۷. Clustering
 ۸. Feature Extraction
 ۹. Subroutines
 10. Projection
 ۱۱. Swap
 ۱۲. Quantum Random Access Memory

۲-۱- یادگیری نظارت شده

یادگیری نظارت شده به سیستمی اشاره دارد که در آن ورودی، مجموعه‌ای از نمونه‌های برچسب‌گذاری شده است و وظیفه سیستم این است که با توجه به ورودی‌ها و برچسب‌های متناظر داده شده، به ازای ورودی‌های جدید، برچسب‌های مناسب را پیش‌بینی کند. وقتی که برچسب‌ها، مقادیر حقیقی هستند مساله، به مساله رگرسیون و وقتی که برچسب‌ها، مقادیر گسسته هستند به مساله طبقه بندی، موسوم هستند (Kerenidis and Prakash, ۲۰۲۰).

۲-۱-۱- رگرسیون

در مسائل رگرسیون، برنامه کامپیوتر آموزش می‌بیند تا یک مقدار عددی را برای یک ورودی m بعدی مفروض پیش‌بینی کند. در واقع هدف این است که تابع مناسب $R \rightarrow h: R^m$ را بیاموزد. در این بخش، الگوریتم‌های کوانتومی برای رگرسیون خطی به روش کمترین مربعات^۱ و برای رگرسیون نزدیکترین k همسایگی^۲ بحث می‌شود که نمونه‌های متناظر پرکاربردترین الگوریتم‌های کلاسیک برای رگرسیون هستند.

رگرسیون خطی به روش کمترین مربعات، یکی از پرکاربردترین الگوریتم‌های یادگیری ماشین برای رگرسیون است. در دنیای کلاسیک، کمترین مربعات خطا، برای مجموعه داده‌های با اندازه متوسط با استفاده از حل کننده‌های سیستم خطی و برای مجموعه داده‌های بزرگ با روش کاهش گرادیان^۳ تکرار شونده حل می‌شود. روش‌های کوانتومی متناظر با الگوریتم‌های مذکور برای کمترین مقدار خطا توسعه یافته اند (Kerenidis and Prakash, ۲۰۲۰). این الگوریتم‌های کوانتومی، راه حل‌های میان مدت هستند زیرا از مدارهای با عمق بالا استفاده می‌کنند. در حوزه علوم مالی، رگرسیون خطی برای قیمت گذاری کالا و برای محاسبه روند چند دارایی^۴ استفاده می‌شود.

نزدیکترین k همسایگی روش غیر پارامتری رگرسیون است که برچسب داده x را به صورت میانگین برچسب k نزدیکترین همسایه x در فاصله اقلیدسی تخمین می‌زند. راه حل کلاسیک حل مساله به علت ابعاد بالای داده و نیاز به محاسبه چندین فاصله اقلیدسی می‌تواند پیچیده و پرهزینه باشد. الگوریتم‌های کوانتومی k نزدیکترین همسایه می‌تواند در آینده نزدیک استفاده شود زیرا زیرروال‌های کوانتومی کارا برای تخمین فاصله وجود دارند که می‌توانند به افزایش سرعت از مرتبه درجه دو به نسبت الگوریتم‌های کلاسیک برسند (Kerenidis, ۲۰۲۰). از کاربردهای نزدیکترین k همسایه در دنیای مالی، می‌توان به سرمایه‌گذاری حق بیمه ریسک دارایی متقابل^۵ اشاره کرد.

۲-۱-۲- طبقه بندی

۱. Least Squares
۲. K-Nearest Neighbor
۳. Descent Gradient
۴. Multi Assesst Computation
۵. Cross-Asset Risk Premia Investing

طبقه‌بندی، به معنی پیش‌بینی برچسب‌های با مقدار گسسته است. در مسائل طبقه‌بندی برنامه کامپیوتر می‌آموزد که تابع مناسب $h: R^m \rightarrow \{1, 2, \dots, t\}$ را بیابد. برنامه آموزش دیده به کمک h برای یک ورودی مفروض تعیین می‌کند به کدام طبقه از t طبقه اختصاص دارد. در این خصوص ضروری است که الگوریتم‌های طبقه‌بندی کوانتومی بر مبنای دو الگوریتم نزدیک‌ترین همسایه و ماشین بردار پشتیبان^۱ تحلیل و بحث شود.

طبقه‌بندی نزدیک‌ترین همسایه، مجموعه‌ای از مراکز را به عنوان ورودی می‌پذیرد و به هر نقطه داده، برچسب نزدیک‌ترین مرکز را به عنوان برچسب اختصاص می‌دهد. به علت وجود پروسه‌های کارآمد تخمین فاصله و الگوریتم‌های خوشه بندی کوانتومی برای یافتن مراکز، امکان پیاده سازی عملی این روش در آینده نزدیک وجود دارد.

الگوریتم ماشین‌های بردار پشتیبان، از پرکاربردترین الگوریتم‌های بینایی ماشین نظارت شده و زیرمجموعه‌ای از الگوریتم‌های طبقه‌بندی هستند. به کمک این ماشین‌ها، می‌توان ابرصفحه‌ای را یافت که پایگاه داده برچسب گذاری شده را به دو دسته مجزا تقسیم کند. پیشنهادهای زیادی برای برای پیاده‌سازی ماشین‌های بردار پشتیبان بر روی کامپیوتر کوانتومی وجود دارد (Chatterjee and Yu, ۲۰۱۷) (Rebentrost et al., ۲۰۱۴). این الگوریتم‌ها بسیار مورد توجه قرار گرفته‌اند زیرا در آنها، اعمال مورد نیاز برای ساخت ابرصفحه^۲ و تخصیص یک طبقه به بردار جدید از مرتبه چندجمله‌ای بر حسب $\log n$ است که n بعد فضای بردار است.^۳ با توجه به نوظهور بودن کاربرد کوانتوم در علوم مالی، اما پیشنهادهای اولیه‌ای برای اعمال الگوریتم‌های طبقه‌بندی کوانتومی برای مسائل تشخیص الگو وجود دارد. در حقیقت ایده تشخیص الگو در چارچوب کامپیوتر کوانتومی به صورت آزمایشگاهی اجرایی شده‌است. از مهم‌ترین کاربردهای ماشین‌های بردار پشتیبان در حوزه علوم مالی تحلیل ریسک اعتبار^۴ است.

۲-۲- یادگیری بدون نظارت

یادگیری بدون نظارت دسته‌ای از روش‌های یادگیری ماشین برای کشف الگوهای موجود در میان داده‌ها است. داده‌های ارائه شده به الگوریتم بدون نظارت دارای برچسب نیستند، بدین معنا که متغیر ورودی (X) بدون هیچ متغیر خروجی متناظری نسبت داده شده است. در یادگیری بدون نظارت، الگوریتم‌ها ساختارهای موجود در میان داده‌ها را کشف می‌کنند. روش‌های یادگیری بدون نظارت به روش‌های خوشه بندی^۵، استخراج ویژگی، مدل‌های ترکیبی یادگیری^۶ و مدل‌های مولد^۷ تقسیم بندی می‌شوند. الگوریتم‌های کوانتومی پیشنهاد شده برای این مدل‌ها در ادامه تبیین شده است.

۲. Support Vector Machine
۳. Hyperplane

۴. گام‌های عملیاتی پیاده‌سازی آزمایشگاهی ماشین بردار پشتیبان کوانتومی در این مقاله ارائه شده‌است: (Li et al., ۲۰۱۹)

۵. Credit Risk
۱. Clustering
۲. Mixture Learning Models
۳. Generative Models

۱-۲-۲- خوشه بندی

الگوریتم کلاسیک k میانگین، یکی از پرکاربردترین الگوریتم‌های خوشه بندی برای مقادیر حقیقی است. در هر مساله خوشه بندی، پایگاه داده‌ای از n بردار داده می‌شود و قرار است به هر بردار یکی از k برچسب تخصیص داده شود (فرض بر این است که k مفروض است)، به گونه‌ای که بردارهای مشابه، به یک خوشه تخصیص داده شوند. اغلب، فاصله اقلیدسی معیار شباهت است، هر چند بسته به موضوع مورد بحث، سایر معیارها نیز ممکن است در نظر گرفته شوند.

برای حل این مساله بر روی کامپیوتر کوانتومی، الگوریتمی به اسم q میانگین پیشنهاد شده است که نسخه متناظر الگوریتم k میانگین است. الگوریتم q میانگین، همگرایی و دقتی شبیه الگوریتم k میانگین دارد و زمان اجرای آن بر حسب اندازه داده ورودی چند جمله‌ای-لگاریتمی است (Kerenidis et al., ۲۰۱۸). الگوریتم q میانگین در آینده نزدیک قابل پیاده سازی است که با الگوریتم تخمین فاصله و ضرب ماتریسی اجرا می‌شود. به یکی از کاربردهای q میانگین در حوزه علوم مالی می‌توان به تحلیل ریسک سبد سهام^۱ اشاره کرد.

خوشه بندی طیفی^۲ الگوریتم یادگیری ماشین برای خوشه بندی داده با ساختارهای غیرمحدب و یا لانه‌ای است (Von Luxburg, ۲۰۰۷). این روش بر مبنای نظریه گراف‌ها از ویژگی‌های طیفی ماتریس لاپلاس برای تصویرکردن داده در فضای با ابعاد پایین بهره می‌گیرد تا خوشه بندی کارا تر محقق شود. با وجود موفقیت این روش در عمل، زمان اجرای این الگوریتم به سرعت رشد می‌کند زیرا زمان اجرای این الگوریتم در کامپیوتر کلاسیک بر حسب تعداد داده‌های ورودی $O(n^3)$ است. الگوریتم کوانتومی بدین منظور ارائه شده است که پیچیدگی آن بر حسب اندازه ورودی خطی است. شبیه سازی‌ها نشان می‌دهد که در دقت یکسان الگوریتم کوانتومی بسیار سریع تر از الگوریتم کلاسیک اجرا می‌شود (Jordanis and Landman, ۲۰۲۱).

الگوریتم کلاسیک k میانگین به الگوریتم بیشینه سازی انتظار^۳ برای یادگیری مدل‌های ترکیبی گوسی تعمیم پیدا می‌کند و همچنین الگوریتم q میانگین می‌تواند به الگوریتم بیشینه سازی انتظار کوانتومی توسعه پیدا کند (Kerenidis et al., ۲۰۲۰).

با فرض دسترس کوانتومی به پایگاه داده، الگوریتم بیشینه سازی انتظار کوانتومی همگرایی داشته و دقتی مشابه نسخه متناظر کلاسیک دارد. در حالی که زمان اجرا بر حسب تعداد داده‌های موجود در مجموعه آموزش چند جمله‌ای لگاریتمی و بر حسب سایر پارامترها (از قبیل بعد فضای ویژگی و تعداد مولفه‌های ترکیبی) چندجمله‌ای است. مهم ترین کاربردهای احتمالی الگوریتم بیشینه سازی انتظار کوانتومی در علوم مالی شامل شناسایی بخش‌ها و ناحیه‌های بازار، تلاطمات و نوسانات^۴، و نوسانات قیمت‌ها و نرخ ارز است.

۲-۲-۲- استخراج ویژگی

۴. Portfolio Risk Analysis
 ۵. Spectral Clustering
 ۱. Expectation-Maximization
 ۲. Volatility

استخراج ویژگی فرایندی است که در آن با انجام عملیاتی بر روی داده‌ها، ویژگی‌های بارز و تعیین‌کننده آن مشخص می‌شود. هدف استخراج ویژگی این است که داده‌های خام به شکل قابل استفاده‌تری برای پردازش‌های آماری بعدی درآیند و داده‌ها در فضای با ابعاد بزرگ به فضایی با ابعاد کمتر تبدیل شود. تصویر کردن بر روی فضای بردار ویژه^۱ ماتریس داده یکی از پراستفاده‌ترین روش‌های استخراج ویژگی و کاهش ابعاد در روش یادگیری ماشین کلاسیک است. الگوریتم‌هایی مانند تحلیل مولفه اصلی^۲ یا تحلیل جداکننده کلاسیک^۳، از چنین تصویرگرهایی استفاده می‌کنند. الگوریتم‌های تحلیل مولفه اصلی کوانتومی بر حسب ابعاد مساله به افزایش سرعت نسبت به نمونه‌های کلاسیک خود منجر می‌شود (Lloyd et al., ۲۰۱۴). الگوریتم‌های جدید تصویرسازی کوانتومی از روش‌های تخمین مقدار منفرد^۴ (Kerenidis and Prakash, ۲۰۱۷) و یا تبدیل مقدار منفرد (Gilyén et al., ۲۰۱۸) استفاده می‌کنند.

۳-۲- یادگیری عمیق

روش‌های متعددی برای یادگیری عمیق کوانتومی بر اساس مدارات کوانتومی پارامتری ارائه شده‌است که عملکردی مشابه با شبکه‌های عصبی متناظر کلاسیک دارد در حالی که به افزایش سرعت کوانتومی برای آموزش می‌توان رسید. شبکه‌های عصبی پیش‌نگر کوانتومی در این حوزه پیشنهاد شده‌اند که می‌توانند در ارزیابی مستقیم و آموزش متبني بر داده‌های پس‌نگر بسیار کارا رفتار کنند (Allcock et al., ۲۰۲۰). اخیراً یک شبکه عصبی کانولوشنال^۵ کوانتومی با افزایش سرعت در آموزش و انتشار به عقب ارائه شده‌اند (Kerenidis et al., ۲۰۲۰). ساختارهای کوانتومی برای یادگیری عمیق، حوزه پژوهشی جدید و رو به پیشرفت است که پیشرفت‌های اخیر شامل اجرای شبکه‌های عصبی کانولوشنال کوانتومی است (Cong et al., ۲۰۱۹) (Chakrabarti et al., ۲۰۱۹). کاربردهای روش یادگیری عمیق و به دنبال آن روش‌های یادگیری عمیق کوانتومی در علوم مالی حوزه‌ای در حال گسترش است (Culkin and Das, ۲۰۱۷). اخیراً راه‌حل‌هایی که مبتنی بر یادگیری عمیق کوانتومی پیشنهاد شده‌اند نسبت به نسخه‌های کلاسیک متناظر خود در حوزه‌های مختلف دانش مالی از قبیل قیمت‌گذاری، خطر رهن^۶ و دفتر سفارشات محدود^۷ برتری چشم‌گیری دارند. هرچند در تحلیل سری‌های زمانی عموماً روش‌های کلاسیک نسبت به روش‌های کوانتومی برتری دارند (Chen et al., ۲۰۱۹).

۴-۲- یادگیری تقویتی

در این حوزه از یادگیری ماشین، داده‌ها و برچسب‌ها موجود نبوده و داده‌ها باید به وسیله ماشین تولید شده و فرایند تولید داده را با بهینه‌سازی یک تابع جایزه مفروض بهینه کند (Kolm and Ritter, ۲۰۲۰). این روش تا

۳. Eigen-Value
 ۴. Principal Component Analysis
 ۵. Linear Discriminant Analysis
 ۶. Singular Value Estimation
 ۷. Convolutional Neural Network
 ۱. Mortgage Risk
 ۲. Limit Order Book

حدی شبیه بازی کودکان است به این معنا که کودک با محیط ارتباط برقرار می‌کند و در ابتدا رفتارهای تصادفی انجام می‌دهد. سپس با بازخوردهای بیرونی (تشویق یا سرزنش والدین) کودک یاد می‌گیرد که خود را بهبود دهد. از طریق یادگیری تقویتی، ماشین‌ها می‌توانند بازی‌های کامپیوتری که در ابتدا به نظر می‌رسید بر مبنای ماشین‌ها قابل مدیریت نیستند را مدیریت کنند.

کنترل پویا بازارهای مالی، یک زمین بازی طبیعی برای الگوریتم‌های یادگیری تقویتی است. پژوهش‌های بسیاری برای مسائل مدیریت ریسک پویا در موارد مبتنی بر مدل، به کمک ابزار برنامه نویسی دینامیک در زمان گسسته یا پیوسته انجام شده‌است. در چنین ساختاری، اگر شبیه‌سازی واقعی از بازار مالی وجود داشته باشد، الگوریتم‌های یادگیری تقویتی، راهی برای روش‌های تقریب عددی بدون مدل برای راهبردهای پوششی^۱ باز می‌کند. چنین شبیه‌سازی ممکن است به طور معمول شامل نواقص بازار مانند افزایش هزینه‌های معامله، تاثیر اندازه بازار و مشکلات مرتبط با تامین نقدینگی شود. چند حوزه مهم کاربرد یادگیری تقویتی در علوم مالی شامل قیمت‌گذاری و پوشش ریسک مشتقات مالی،^۲ تخصیص بهینه دارایی،^۳ مدل سازی تاثیر بازار^۴ و معاملات الگوریتمی است (Charpentier et al., ۲۰۲۱). در همین راستا آموزش تقویتی کوانتومی حوزه‌ای نسبتاً جدید است که منجر به افزایش سرعت نسبت به الگوریتم‌های کلاسیک شده‌است (Ramezanpour, ۲۰۱۷) (Albarrán-Arriagada et al., ۲۰۱۸).

۵-۲- جمع‌بندی

جدول (۱)، مسائل علوم مالی که روش‌های یادگیری ماشین کوانتومی می‌توانند به افزایش سرعت و کارایی کوانتومی در حل آنها منجر شوند، را جمع‌بندی می‌کند. همچنین الگوریتم کوانتومی مناسب حل آن کاربرد خاص، میزان افزایش سرعت و همچنین زمان تحقق فیزیکی آن نیز اعلام شده‌است. در این جدول، N اندازه ورودی مساله و منظور از افزایش سرعت $O(\sqrt{N})$ این است که اگر زمان صرف شده برای حل کلاسیک آن مساله مالی، ضریبی از N باشد، زمان حل کوانتومی آن، ضریبی از \sqrt{N} است همچنین منظور از افزایش سرعت $O(\log N)$ این است که اگر زمان صرف شده برای حل کلاسیک آن مساله مالی، ضریبی از N باشد، زمان حل کوانتومی آن، ضریبی از $\log N$ است. (Cormen et al., ۲۰۰۹) به عنوان نمونه، اگر زمان صرف شده برای یک مساله بر روی کامپیوتر کلاسیک 10^{12} واحد زمانی باشد، حل آن با الگوریتم کوانتومی دارای افزایش سرعت $O(\sqrt{N})$ ، 10^6 واحد زمانی خواهد بود که یک میلیون بار سریعتر است. همچنین حل آن مساله با الگوریتم کوانتومی دارای افزایش سرعت $O(\log N)$ فقط 12 واحد زمانی است. به افزایش سرعت از مرتبه $O(\sqrt{N})$ افزایش سرعت چندجمله‌ای^۵ و به افزایش سرعت از مرتبه $O(\log N)$ افزایش سرعت نمایی^۶ گفته می‌شود.

۳. Hedging Strategies
 ۴. Pricing and Hedging of Financial Derivatives
 ۵. Optimal Asset Allocation
 ۶. Market Impact Modeling
 ۱. Quadratic
 ۲. Exponential

همانطور که مشاهده می شود روشهای حل کوانتومی کاربرد گسترده‌ای در حل مسائل مالی داشته و به‌ویژه در روشهای پرکاربرد مدل‌سازی تحلیل مالی شامل روشهای رگرسیون و خوشه‌بندی قادر به تحلیل طیف گسترده‌ای از مسائل از جمله بهینه‌یابی‌ها، قیمت‌گذاری داراییها، تحلیل سبد سهام، معاملات الگوریتمی، پیش‌بینی‌های نرخ تورم و محاسبات حوزه ریسک‌سنجی هستند.

ویراست نشده، غیر قابل انتشار

جدول ۱: کاربرد روش‌های یادگیری کوانتومی در حل مسائل علوم مالی (منبع: یافته‌های پژوهش)

مساله کاربردی در حوزه علوم مالی	دسته	روش حل کوانتومی	میزان افزایش سرعت در دقت مشابه با فرض اندازه ورودی برابر N	زمان تحقق پیاده‌سازی عملی
<ul style="list-style-type: none"> • قیمت گذاری کالا • محاسبه روند چند دارایی 	رگرسیون	رگرسیون خطی کوانتومی (Kerenidis and Prakash, ۲۰۲۰)	$O(\sqrt{N})$	آینده میان‌مدت
سرمایه‌گذاری حق بیمه ریسک دارایی متقابل	رگرسیون	نزدیکترین k همسایگی کوانتومی (Kerenidis, ۲۰۲۰)	$O(\sqrt{N})$	آینده کوتاه‌مدت
تحلیل ریسک اعتبار	طبقه‌بندی	ماشین بردار پشتیبان کوانتومی (Chatterjee and Yu, ۲۰۱۷)	$O(\log N)$	پیاده‌سازی شده‌است
تحلیل ریسک سبد سهام	خوشه‌بندی	الگوریتم q میانگین (Kerenidis et al., ۲۰۱۸)	$O(\log N)$	آینده کوتاه‌مدت
<ul style="list-style-type: none"> • شناسایی نواحی بازار • بالا/پایین رفتن نوسانات • افزایش/کاهش نرخ‌ها • افزایش/کاهش تورم 	خوشه‌بندی	الگوریتم پیشینه‌سازی انتظار کوانتومی (Anupam Prakash, ۲۰۲۰)	$O(\log N)$	آینده کوتاه‌مدت
کاهش ابعاد داده‌های متنوع مالی	استخراج ویژگی	الگوریتم‌های تحلیل مولفه اصلی کوانتومی (Lloyd et al., ۲۰۱۴.) الگوریتم تصویرسازی کوانتومی (Kerenidis and Prakash, ۲۰۱۷) (Gilyén et al., ۲۰۱۸)	$O(\sqrt{N})$	آینده کوتاه‌مدت

آینده کوتاه مدت	$O(\sqrt{N})$	شبکه عصبی کانولوشنال کوانتومی (Chakrabarti et al., ۲۰۱۹) (Cong et al., ۲۰۱۹) شبکه‌های عصبی پیش‌نگر کوانتومی (Allcock et al., ۲۰۲۰)	یادگیری عمیق	<ul style="list-style-type: none"> • قیمت دارایی • دفتر سفارشات محدود • خطر رهن • پیش‌بینی بازار سهام • معاملات سهام • ریسک و اعتبار پیش فرض مالی
آینده کوتاه مدت	$O(\sqrt{N})$	یادگیری تقویتی کوانتومی (Albarrán-Arriagada et Ramezanzpour, ۲۰۱۷) al., ۲۰۱۸)	یادگیری تقویتی	<ul style="list-style-type: none"> • قیمت‌گذاری و پوشش ریسک مشتقات مالی • تخصیص بهینه مالی • مدل‌سازی تاثیر بازار • معاملات الگوریتمی

ویژگی‌های مقاله، غیر قابل انتشار

نتیجه گیری

این پژوهش به بررسی مبانی نظری محاسبات و تکامل کامپیوترهای کوانتومی از منظر اثر بر محاسبات علوم مالی بر مبنای روش‌های یادگیری ماشین پرداخت. تمرکز اصلی در مرور مبانی نظری و محاسباتی ماشین‌های کوانتومی، پاسخ به دو سوال اصلی بود. ۱- چگونه توان محاسبات کوانتومی سرعت محاسبات را در حوزه علوم مالی افزایش می‌دهد؟ ۲- کدام یک از این افزایش سرعت‌ها قابلیت پیاده‌سازی عملی را در کوتاه مدت خواهند داشت؟ بررسی پژوهش‌های در حال گسترش و تکامل نشان داد که افزایش قدرت محاسباتی و دسترس‌پذیر بودن داده‌های بزرگ به همراه توسعه الگوریتم‌ها باعث پیشرفت‌های عظیم روش‌های یادگیری ماشین شده‌اند. همچنین نزدیکی به محدودیت‌های فیزیکی تولید تراشه‌های سیلیکونی به همراه رشد روزافزون حجم مجموعه داده پژوهشگران حوزه‌های مختلف علوم و از جمله علوم مالی را ترغیب کرده‌است که از قدرت محاسبات کوانتومی برای افزایش سرعت الگوریتم‌های کلاسیک یادگیری ماشین استفاده کنند. در این مقاله، با بررسی روش‌های موثر بر یادگیری ماشین کوانتومی، به کاربردهای حل کوانتومی در حل مسائل مالی اشاره شد.

در بررسی کاربردهای محاسبات کوانتومی در اقتصاد مالی و اهمیت آن، نشان داده شد که گسترش قابل توجه کاربردهای محاسبات کوانتومی در علوم مالی دو علت اصلی دارد: (۱) تحولات در حال توسعه و فراتر از انتظارات در سخت‌افزار کوانتومی، و (۲) پیشرفت مبانی نظری و مفهومی نظریات کوانتومی، که افزایش نمایی سرعت محاسبات در الگوریتم‌های کوانتومی به طور گسترده و کاربردی در تمام علوم و از جمله علوم مالی که نیاز به دقت و سرعت بالاتر در پردازش اطلاعات دارد را امکان‌پذیر نموده است. در این راستا چهار الگوریتم پرکاربرد شامل (۱) طبقه‌بندی داده‌ها با هدف تشخیص سریع و دقیق الگوها در میان داده‌ها، (۲) روش‌های رگرسیون با تمرکز بر تشخیص فرم تابعی داده‌ها، (۳) روش تحلیل مولفه‌های اصلی با هدف تقلیل داده‌ها به چند مولفه اصلی و تعیین روندهای هم‌حرکتی میان داده‌های بزرگ، و (۴) شبکه‌های عصبی با تمرکز بر شناسایی و تعیین الگوهای رفتاری بر اساس

شهود ذاتی داده‌ها تحلیل و بحث شد. همچنین بر این نکته تاکید شد که هنوز تا تحقق عملیاتی برخوردار از محاسبات کوانتومی در علوم مالی فاصله زیادی وجود داشته و مستلزم پیشرفت‌های زیادی است تا به یک پردازنده کوانتومی برای اجرای الگوریتم‌های محاسبات کوانتومی دست پیدا کرد. در نهایت نیز مهم‌ترین کاربردهای محاسبات کوانتومی در اقتصاد مالی بررسی شد. همچنین نقش فناوریهای کوانتومی در بهینه‌یابی‌های اقتصادی و مالی و مباحث مربوط به قیمت‌گذاری و ریسک سنجی و اینکه چگونه با افزایش دقت و سرعت نسبت به روشهای کلاسیک الگوریتم‌های محاسباتی را بهبود می‌دهند تحلیل شد.

نتایج این مطالعه تاکید می‌کند که یادگیری ماشین کوانتومی با دو معیار سرعت و دقت کاربرد و سنجی در روشهای پرکاربرد مدل‌سازی تحلیل مالی شامل روشهای رگرسیون و خوشه‌بندی قادر به تحلیل طیف گسترده‌ای از مسائل از جمله بهینه‌یابی‌ها، قیمت‌گذاری داراییها، تحلیل سبد سهام، معاملات الگوریتمی، پیش‌بینی‌های نرخ تورم و محاسبات حوزه ریسک سنجی دارند. بنابراین ضروری است که سیاست‌گذاران و متخصصین حوزه علوم مالی با توجه به مزایای بکارگیری ماشین‌های کوانتومی، برنامه‌ریزی‌های لازم برای تامین مالی پروژه‌های گذار به نسل کامپیوترهای کوانتومی را پیگیری نمایند.

بر اساس نتایج این پژوهش پیشنهاد می‌شود که با توجه به کاربرد وسیع محاسبات کوانتومی در فناوری بلاک‌چین، رمزارزها و مباحث مرتبط با امنیت و مدیریت بهینه معاملات مالی با بکارگیری شبیه‌سازیهای کوانتومی، عملیاتی کردن روش‌های یادگیری ماشین‌های کوانتومی در علوم مالی به صورت یک ضرورت مورد توجه قرار گیرد. همچنین با توجه به مهم‌ترین ویژگی و نقطه مشترک مسائل در اقتصاد مالی که ماهیت عدم قطعیت در پیش‌بینی رفتار آینده متغیرها، ارزش‌گذاری دارایی‌ها و بازده آنها است، یکی از روشهای کاهش ریسک، تجزیه و تحلیل رفتار دارایی‌ها بصورت پیوسته و مبتنی بر اطلاعات لحظه‌ای بازار است که استفاده از ماشین‌های یادگیری کوانتومی با کارایی فنی و تخصیصی می‌تواند نقش موثری در بهینه‌سازی معاملات و کاهش ریسک داشته باشد.

- Albarrán-Arriagada, Francisco, et al. (۲۰۱۸). Measurement-based adaptation protocol with quantum reinforcement learning. *Physical Review A*, 98.4.
- Alcazar, J., Leyton-Ortega, V., & Perdomo-Ortiz, A. . (۲۰۲۰). Classical versus quantum models in machine learning: insights from a finance application. *Machine Learning: Science and Technology*, ۱(۳).
- Allcock, J., Hsieh, C.Y., Kerenidis, I., and Zhang, S. (۲۰۲۰). Quantum algorithms for feedforward neural networks. *ACM Transactions on Quantum Computing*, 1(1), ۱-۲۴.
- Arute, F, et al. (۲۰۱۹). Quantum supremacy using a programmable superconducting processor. *Nature*, ۵۷۵-۵۱۰.
- Biamonte, Jacob, et al. (۲۰۱۷). Quantum machine learning . *Nature* ۵۴۹, ۷۶۷۱, ۱۹۵-۲۰۲.
- Blackstad, R. B. and Ospelkaus, C. (۲۰۱۹). High fidelity transport of trapped-ion qubits through an X-junction trap array. *Quantum Information and Computation*, 9, ۹۲۰-۹۴۹.
- Carrasquilla, J. (۲۰۲۰). Machine learning for quantum matter. *Advances in Physics*, X 5.1.
- Chakrabarti, S., Yiming, H., Li, T., Feizi, S., and Wu, X. (۲۰۱۹). Quantum Wasserstein generative adversarial networks. *Advances in Neural Information Processing Systems*, ۶۷۸۱-۶۷۹۲.
- Charpentier, A., Romuald, E., and Remlinger, C. (۲۰۲۱). Reinforcement learning in economics and finance. *Computational Economics*, ۱-۳۸.
- Chatterjee, R., and Yu, T. (۲۰۱۷). Generalized coherent states, reproducing kernels, and quantum support vector machines. *Quantum Information and Computation*, 17, 1292.
- Chen, L., Pelger, M., and Zhu, J. (۲۰۱۹). *Deep learning in asset pricing*. SSRN, Report No. ۳۳۵۰۱۳۸.
- Chong, Frederic T., Diana Franklin, and Margaret Martonosi. (۲۰۱۷). Programming languages and compiler design for realistic quantum hardware. *Nature* 549.7671, ۱۸۰-۱۸۷.

- Cong, I., Choi, S., and Lukin, M. (2019). Quantum convolutional neural networks. *Nature Physics*, 15(12), 1273–1278.
- Cormen, T. H., Leiserson, C. E., Rivest, R. L., & Stein, C. (2009). *Introduction to algorithms*. MIT press.
- 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.
- Ding, Y. et al. (2019). *Towards Prediction of Financial Crashes with a D-Wave Quantum Computer*. Working paper, URL: <https://arxiv.org/pdf/1904.08088.pdf>.
- Dixon, M.F., Halperin, I., and Bilokon, P. (2020). *Machine Learning in Finance*. Springer International Publishing.
- Fanizza, Marco, et al. (2020). Beyond the swap test: optimal estimation of quantum state overlap. *Physical review letters*, 124.6.
- Gilyén, A., Su, Y., Low, G., and Wiebe, N. (2018). Quantum singular value transformation and beyond: exponential improvements for quantum matrix arithmetics. *In Proceedings of the 51st Annual ACM SIGACT Symposium on Theory of Computing*.
- Haener, Thomas, et al. (2018). Quantum circuits for floating-point arithmetic. *International Conference on Reversible Computation*. Springer, Cham.
- Harrow, A.W., Hassidim, A., and Lloyd, S. (2009). Quantum algorithm for linear systems of equations. *Physical review letters*, 103(15):150502.
- Home, J. P., Hanneke, D. and Jost, J. . (2009). Complete methods set for scalable ion trap quantum information processing. *Science*, 325.
- Houshmand, Monireh, Mahboobeh Houshmand, and Joseph F. Fitzsimons. (2018). Minimal qubit resources for the realization of measurement-based quantum computation . *Physical Review A*, 98,1.
- Hu, Feng, et al. (2019). Quantum machine learning with D-wave quantum computer. *Quantum Engineering*, 1.2 : e12.
- Hull, I., Sattath, O., Diamanti, E., and Wendin, G. (2021). *Quantum Technology for Economists*. Papers 2012.04473, arXiv.org.
- Iordanis, K., and Landman, J. (2021). Quantum spectral clustering. *Physical Review A*, 103.4.

- Itay, E., and Spedalieri, F.M. (۲۰۱۶). Quantum annealing for constrained optimization. *Physical Review Applied*, 5.3.
- Kerenidis, I. (۲۰۲۰). *A method for loading classical data into quantum states for applications in machine learning and optimization*. U.S. Patent Application No. ۱۶/۹۸۶,۰۵۳ and ۱۶/۹۸۷,۲۳۵.
- Kerenidis, I., Landman, J., and Prakash, A. (۲۰۲۰). Quantum algorithms for deep convolutional neural networks. *Proceedings of International Conference on Learning Representations (ICLR)*.
- Kerenidis, Iordanis, et al. (۲۰۱۸). q-means: A quantum algorithm for unsupervised machine learning. *arXiv preprint arXiv, 1812.03584*.
- Kerenidis, I., and Prakash, A. (۲۰۱۷). Quantum recommendation systems. *Proceedings of the 8th Innovations in Theoretical Computer Science Conference*.
- Kerenidis, I., and Prakash, A. (۲۰۲۰). Quantum gradient descent for linear systems and least squares. *Physical Review A*, 101(2).
- Kerenidis, I., Luongo, A., and Prakash, A. (۲۰۲۰). Quantum expectation-maximization for Gaussian mixture models. *Proceedings of International Conference on Machine Learning (ICML)*.
- Kolm, P.N., and Ritter, G. (۲۰۲۰). Modern perspectives on reinforcement learning in finance. *The Journal of Machine Learning in Finance*, ۱,۱.
- Kwangwon, A., Choi, M., Dai, B., Sohn, S., and Yang, B. (۲۰۱۸). Modeling stock return distributions with a quantum harmonic oscillator. *EPL (Europhysics Letters) 120: 38003*.
- Lessmann, S., Baesens, B., Seow, H.V., Thomas, L.C. (۲۰۱۵). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, 247 (1).
- Lloyd, S., Mohseni, M., and Rebentrost, P. (۲۰۱۴). Quantum principal component analysis. *Nature Physics*, 10(9):631.
- Lpaydin, E. (۲۰۲۰). *Introduction to machine learning*. MIT press.
- Marinescu, D. C., and Marinescu, G. M. (۲۰۰۴). *Approaching quantum computing*. Prentice Hall.
- Martin, Ana, et al. (۲۰۲۱). Toward pricing financial derivatives with an IBM quantum computer. *Physical Review Research*, 3.1.

- Meter, R. V. and Oskin, M. (۲۰۰۶). Architectural implications of quantum computing technologies. *ACM Journal on Emerging Technologies in Computing Systems*, 2, ۳۱-۶۳.
- Mosteanu, N.R., and Faccia, A. (۲۰۲۱). Fintech Frontiers in Quantum Computing, Fractals, and Blockchain Distributed Ledger: Paradigm Shifts and Open Innovation. *JOItmC, MDPI*, vol. 7(1), ۱-۱۹.
- Mousavi, M., Houshmand, M., & Bolokian, M. (۲۰۲۱). The Cost Reduction of Distributed Quantum Factorization Circuits. *International Journal of Theoretical Physics*, 60(۴), ۱۲۹۲-۱۲۹۸.
- Nielsen, M.A. and Chuang, I.L. (۲۰۱۰). *Quantum Computation and Quantum Information*. Cambridge University Press.
- Orús, R., Mugel, S., and Lizaso, E. (۲۰۱۹). Quantum computing for finance: Overview and prospects. *Reviews in Physics* 4.
- Ramezanzpour, A. (۲۰۱۷). Optimization by a quantum reinforcement algorithm. *Physical Review A*, 96.5.
- Rebentrost, P., Mohseni, M., and Lloyd, S. (۲۰۱۴). Quantum support vector machine for big data classification. *Physical Review Letters*, 113, 1.
- Sergio, F., Fabozzi, F.J., and Mazza, D. (۲۰۲۰). Quantum Option Pricing and Quantum Finance. *The Journal of Derivatives*, 28.1, ۷۹-۹۸.
- Spiller, T. P., Munro, W., Barrett, S. and Kok, P. (۲۰۰۵). An introduction to quantum information processing: applications and realizations. *Contemporary Physics*, 46, ۴۰۷-۴۳۶.
- Stamatopoulos, N., Egger, D. J., Sun, Y., Zoufal, C., Iten, R., Shen, N., and Woerner, S. (۲۰۲۰). Option pricing using quantum computers. *Quantum*, 4, 291. doi:<https://doi.org/10.22331/q-2020-07-06-291>
- Von Luxburg, U. (۲۰۰۷). A tutorial on spectral clustering. *Statistics and computing*, 17.4, ۳۹۵-۴۱۶.
- Z. Li, X. Liu, N. Xu, and J. Du. (۲۰۱۵). Experimental realization of a quantum support vector machine. *Physical Review Letters*, 114.
- Zhang, Yao, and Qiang Ni. (۲۰۲۰). Recent advances in quantum machine learning. *Quantum Engineering*, 2.1: e34.

ویراست نشده، غیر قابل انتشار