

معماری‌های هیبرید کوانتومی-کلاسیک برای شتاب‌دهی به الگوریتم‌های یادگیری ماشین

حمیدرضا حنیف

کارشناسی ارشد ریاضی دانشگاه علم و صنعت ایران

h_hanif@mathdep.iust.ac.ir

چکیده

پیشرفت‌های اخیر در فناوری محاسبات کوانتومی، علاقه فزاینده‌ای را به توسعه و بررسی معماری‌های محاسباتی هیبرید برانگیخته است که در آن پردازنده‌های کوانتومی و کلاسیک به صورت هماهنگ برای حل مسائل محاسباتی پیچیده عمل می‌کنند. این مقاله به بررسی سیستماتیک نقش و پتانسیل این معماری‌های هیبرید در شتاب‌دهی و بهبود الگوریتم‌های یادگیری ماشین می‌پردازد. با وجود چالش‌های موجود در مقیاس‌پذیری و نویز پردازنده‌های کوانتومی فعلی (NISQ)، معماری‌های هیبرید پارادایمی امیدوارکننده برای بهره‌گیری اولیه از مزیت کوانتومی در مسائل عملی ارائه می‌دهند. این مقاله مروری جامع بر مفاهیم پایه، چارچوب‌های الگوریتمی کلیدی (مانند مدل‌های کوانتومی-کلاسیک ترکیبی، الگوریتم‌های variational یا VQAs، و یادگیری ویژگی کوانتومی)، حوزه‌های کاربردی (شامل شیمی کوانتومی، بهینه‌سازی و تشخیص الگو)، و چالش‌های فنی و آینده این حوزه ارائه می‌کند. تحلیل‌ها نشان می‌دهند که در کوتاه‌مدت و میان‌مدت، الگوریتم‌های هیبرید احتمالاً بیشترین تأثیر را در حل مسائل یادگیری ماشین خواهند داشت و در نهایت ممکن است راه را برای الگوریتم‌های کاملاً کوانتومی هموار کنند. این بررسی بر اساس ادبیات پژوهشی به روز (بین سال‌های ۲۰۲۰ تا ۲۰۲۵) انجام شده و شامل بحث در مورد نتایج تجربی اخیر، معیارهای ارزیابی و روندهای آینده است.

کلمات کلیدی: محاسبات کوانتومی، یادگیری ماشین، الگوریتم‌های هیبرید

۱. مقدمه

انقلاب دیجیتال کنونی به شدت متکی بر توانایی پردازش حجم عظیمی از داده‌ها و استخراج الگوهای معنادار از آن‌ها است. یادگیری ماشین (ML) به عنوان زیرمجموعه‌ای از هوش مصنوعی، ابزارهای قدرتمندی برای این منظور توسعه داده است. با این حال، با افزایش پیچیدگی مدل‌ها و ابعاد داده‌ها، نیاز به توان محاسباتی بیشتر به یک چالش اساسی تبدیل شده است. از سوی دیگر، محاسبات کوانتومی، با بهره‌گیری از اصول مکانیک کوانتومی مانند درهم‌نهی و درهم‌تنیدگی، نوید حل برخی مسائل محاسباتی را با سرعتی نمایی نسبت به بهترین ابررایانه‌های کلاسیک می‌دهد.

با این وجود، عصر محاسبات کوانتومی مقیاس‌پذیر و عاری از خطا (فراگیر کوانتومی) هنوز در افق دور قرار دارد. آنچه امروزه در دسترس است، پردازنده‌های کوانتومی در مقیاس متوسط و پرنویز (Quantum Intermediate-Scale Noisy یا NISQ) هستند (Preskill, 2018). این پردازنده‌ها دارای تعداد کیوبیت محدود (از ده‌ها تا چند صد) و نرخ خطای قابل توجه هستند که اجرای الگوریتم‌های کوانتومی پیچیده و طولانی مانند الگوریتم شور برای تجزیه اعداد را غیرعملی می‌سازد. در پاسخ به این محدودیت‌ها، پارادایم محاسبات هیبرید کوانتومی-کلاسیک ظهور کرده است. در این پارادایم، وظایف محاسباتی بین یک پردازنده کوانتومی (که عموماً بخشی از محاسبات را که ممکن است از مزیت کوانتومی بهره‌بردار انجام می‌دهد) و یک پردازنده کلاسیک قدرتمند (که بقیه کار شامل کنترل، بهینه‌سازی و پردازش داده را مدیریت می‌کند) تقسیم می‌شود.

تمرکز اصلی این مقاله بر کاربرد این معماری‌های هیبرید در حوزه یادگیری ماشین است. سؤال پژوهشی اصلی این است: «معماری‌های هیبرید کوانتومی-کلاسیک چگونه می‌توانند الگوریتم‌های یادگیری ماشین را شتاب بخشند یا بهبود دهند، و چالش‌ها و محدودیت‌های فعلی در این مسیر چیست؟»

هدف این مقاله ارائه بررسی سیستماتیک و به‌روز از این زمینه پژوهشی پویا است. در بخش‌های بعدی، ابتدا پیشینه و مفاهیم پایه شرح داده می‌شود. سپس چارچوب‌های الگوریتمی اصلی معرفی و تحلیل می‌شوند. در ادامه، حوزه‌های کاربردی مشخص مورد بحث قرار گرفته و چالش‌های فنی و آینده این حوزه بررسی می‌شوند. مقاله با یک جمع‌بندی کلی به پایان می‌رسد.

۲. پیشینه و مفاهیم پایه

۱.۲. یادگیری ماشین کلاسیک: یک مرور کوتاه

یادگیری ماشین به ساخت سیستم‌هایی اطلاق می‌شود که داده‌ها یاد می‌گیرند و بهبود می‌یابند. الگوریتم‌های اصلی شامل یادگیری نظارت‌شده (مانند رگرسیون و طبقه‌بندی)، یادگیری بدون نظارت (مانند خوشه‌بندی و کاهش ابعاد) و یادگیری تقویتی است. بسیاری از این الگوریتم‌ها در هسته خود شامل مسائل بهینه‌سازی (مانند کمینه‌کردن تابع هزینه) یا پردازش ماتریس‌های بزرگ هستند. با افزایش پیچیدگی مدل‌هایی مانند شبکه‌های عصبی عمیق، هزینه محاسباتی آموزش به شدت افزایش یافته است.

۲.۲. محاسبات کوانتومی: اصول و وضعیت NISQ

واحد پایه اطلاعات در محاسبات کوانتومی، کیوبیت است که بر خلاف بیت کلاسیک (۰ یا ۱)، می‌تواند در یک درهم‌نهی از دو حالت باشد. یک سیستم با n کیوبیت می‌تواند همزمان نماینده 2^n حالت باشد. عملیات روی کیوبیت‌ها توسط دروازه‌های کوانتومی انجام

می‌شود که یک مدار کوانتومی را تشکیل می‌دهند. الگوریتم‌های کوانتومی با دستکاری این برهم‌نهی‌ها و درهم‌تنیدگی‌ها به نتایجی می‌رسند که پس از اندازه‌گیری، جواب مسئله را با احتمال بالا ارائه می‌دهند.

عصر کنونی، عصر NISQ نامیده می‌شود. پردازنده‌های این عصر دارای ویژگی‌های زیر هستند:

- تعداد کیوبیت محدود (NISQ).
- وجود نویز در عملیات دروازه‌ها و خوانش کیوبیت‌ها.
- عمق مدار محدود (تعداد مراحل محاسباتی قبل از اینکه نویز نتیجه را بی‌معنی کند).
- این محدودیت‌ها، طراحی الگوریتم‌های کوتاه، مقاوم در برابر نویز و هیبرید را ضروری ساخته است (al et Bharti, ۲۰۲۲).

۳.۲. پارادایم محاسبات هیبرید کوانتومی - کلاسیک

ایده اصلی این پارادایم تقسیم کار هوشمندانه است. یک حلقه بازخورد بین پردازنده کوانتومی و کلاسیک برقرار می‌شود:

۱. پردازنده کلاسیک: داده‌های ورودی را آماده کرده، پارامترهای یک مدار کوانتومی را تنظیم می‌کند و یک تابع هزینه را بر اساس خروجی کوانتوم محاسبه می‌کند.
۲. پردازنده کوانتومی: مدار پارامتریشده را اجرا کرده و یک حالت کوانتومی را آماده یا یک کمیت (مانند مقدار انتظاری یک عملگر) را اندازه‌گیری می‌کند. نتیجه (غالباً به صورت کلاسیک) به پردازنده کلاسیک بازگردانده می‌شود.
۳. الگوریتم بهینه‌سازی کلاسیک: پردازنده کلاسیک با استفاده از خروجی کوانتومی، تابع هزینه را ارزیابی کرده و پارامترهای مدار را با استفاده از یک بهینه‌ساز کلاسیک (مانند گرادیان کاهشی) به‌روز می‌کند تا تابع هزینه کمینه شود.
۴. این چرخه تا رسیدن به همگرایی ادامه می‌یابد. قدرت این معماری در این است که از توان کوانتومی برای بخش‌هایی از محاسبه که ممکن است برای کامپیوترهای کلاسیک سخت باشد (مانند تخمین مقادیر ویژه یا نمونه‌برداری از توزیع‌های پیچیده) استفاده می‌کند، در حالی که از قدرت و بلوغ الگوریتم‌های بهینه‌سازی کلاسیک بهره می‌برد.

۳. چارچوب‌های الگوریتمی هیبرید برای یادگیری ماشین

۱.۳. مدارهای کوانتومی متغیر (VQEs) و الگوریتم‌های **variational** کوانتومی (VQAs)

VQAs هسته اصلی اکثر الگوریتم‌های هیبرید در عصر NISQ هستند (al et Cerezo, ۲۰۲۱). در این الگوریتم‌ها، یک مدار کوانتومی با پارامترهای قابل تنظیم (θ) تعریف می‌شود. این مدار، یک حالت کوانتومی **variational** $|\psi\rangle(\theta)$ را تولید می‌کند. هدف، یافتن پارامترهای بهینه θ است که یک تابع هزینه $C(\theta)$ را که اغلب به صورت $\langle\psi(\theta)|H|\psi(\theta)\rangle$ برای یک عملگر معین H (مانند همیلتونی یک سیستم مولکولی) تعریف می‌شود، کمینه کند.

در زمینه یادگیری ماشین، می‌توان از این چارچوب برای انواع مسائل استفاده کرد. برای مثال، در یک طبقه‌بندی کننده **variational** کوانتومی:

- داده ورودی X (و برجسب y) به پارامترهای مدار تزریق می‌شود.

- مدار اجرا شده و اندازه‌گیری‌هایی انجام می‌شود.
- خروجی اندازه‌گیری برای پیش‌بینی برچسب \hat{Y} استفاده می‌شود.
- یک تابع هزینه (مانند خطای بین Y و \hat{Y}) محاسبه می‌شود.
- یک بهینه‌ساز کلاسیک (مانند Adam)، پارامترهای θ را برای کمینه کردن هزینه به‌روز می‌کند.
- انعطاف‌پذیری در طراحی مدار (انکودر داده، لایه‌های پارامتردار، اندازه‌گیری) باعث شده VQAs برای بسیاری از کارهای ML مناسب باشند.

۲.۳. یادگیری ویژگی کوانتومی (QML)

یکی از امیدوارکننده‌ترین کاربردهای مدل‌های هیبرید، یادگیری ویژگی کوانتومی است (al et Havlíček, ۲۰۱۹). ایده این است که از مدار کوانتومی برای نگاشت داده‌های کلاسیک ورودی X به یک فضای ویژگی با ابعاد بالاتر (حتی بینهایت بعد) استفاده شود. این فضا، فضای ویژگی کوانتومی یا Hilbert space است. نگاشت $\phi: X \rightarrow \phi(x)$ می‌تواند غیرخطی و پیچیده باشد. سپس، یک مدل خطی ساده (که می‌تواند به صورت کوانتومی یا کلاسیک پیاده‌سازی شود) روی این ویژگی‌های غنی شده اعمال می‌شود. این شبیه به ماشین بردار پشتیبان (SVM) با هسته در ML کلاسیک است، با این تفاوت که هسته به صورت فیزیکی توسط یک مدار کوانتومی محاسبه می‌شود: $K(x_j, x_i) = \langle \phi(x_j) | \phi(x_i) \rangle$.

مزیت نظری این است که برخی از نگاشت‌های کوانتومی ممکن است قادر به یادگیری الگوهای باشند که برای کامپیوترهای کلاسیک محاسبه آن‌ها سخت است (al et Liu, ۲۰۲۱). البته، بحث‌های جاری در مورد اینکه آیا این مزیت در مدل‌های واقعی با داده‌های واقعی و با حضور نویز محقق می‌شود، ادامه دارد.

۳.۳. مدل‌های ترکیبی کوانتومی-کلاسیک (مثلاً شبکه‌های عصبی هیبرید)

در این معماری، لایه‌های کوانتومی به عنوان بخشی از یک شبکه عصبی عمیق کلاسیک گنجانده می‌شوند. برای مثال، می‌توان لایه‌های اولیه یک شبکه کانولوشنی کلاسیک را برای استخراج ویژگی‌های سطح پایین از داده‌های تصویری استفاده کرد، سپس این ویژگی‌های استخراج‌شده به یک مدار کوانتومی variational تغذیه شده و خروجی آن برای پیش‌بینی نهایی استفاده شود (al et Henderson, ۲۰۲۰). این رویکرد از قدرت مدل‌های کلاسیک برای پیش‌پردازش و کاهش ابعاد داده‌های پیچیده و استفاده از بخش کوانتومی برای انجام محاسبات پیچیده روی ویژگی‌های فشرده‌شده بهره می‌برد.

جدول ۱: مقایسه چارچوب‌های الگوریتمی هیبرید اصلی

| نمونه کاربرد در ML | چالش‌های کلیدی | مزایای کلیدی | ایده اصلی | چارچوب الگوریتمی |
|---|--|---|--|--|
| طبقه‌بندی، رگرسیون، خوشه‌بندی. | مشکل گرادیان ناپدیدشونده (Plateaus Barren)، بهینه‌سازی سخت، وابستگی به ansatz. | انعطاف‌پذیر، مقاوم در برابر نویز (با عمق محدود)، مناسب برای NISQ. | کمینه‌سازی تابع هزینه با تنظیم پارامترهای یک مدار کوانتومی. | الگوریتم‌های variational کوانتومی (VQAs) |
| طبقه‌بندی با هسته کوانتومی، تشخیص الگو. | ارزیابی عملی مزیت، طراحی مدارهای نگاشت مؤثر، حساسیت به نویز. | پتانسیل برای مزیت کوانتومی در یادگیری الگوهای پیچیده، ارتباط با روش‌های هسته. | نگاشت غیرخطی داده به فضای ویژگی با بعد بالا via مدار کوانتومی. | یادگیری ویژگی کوانتومی (QML) |
| پردازش تصویر پیشرفته، ترکیب با CNN/RNN. | آموزش یکپارچه مشکل‌تر، اشکال‌زدایی پیچیده. | بهره‌گیری از قدرت هر دو جهان، کاهش بار روی بخش کوانتومی. | ادغام لایه‌های کوانتومی در میان لایه‌های کلاسیک یک شبکه عصبی عمیق. | شبکه‌های عصبی هیبرید |

۴. حوزه‌های کاربردی

۱.۴. شیمی کوانتومی و کشف مواد

این حوزه یکی از طبیعی‌ترین کاربردهاست. VQAs به‌طور گسترده برای محاسبه ساختار الکترونی و خواص مولکول‌ها استفاده می‌شوند. در یادگیری ماشین، می‌توان از مدل‌های هیبرید برای پیش‌بینی خواص مولکول‌های جدید (مانند انرژی پیوند، فعالیت دارویی) بر اساس داده‌های تولیدشده توسط شبیه‌سازی‌های کوانتومی (کلاسیک یا هیبرید) استفاده کرد. یک چارچوب هیبرید می‌تواند ویژگی‌های مولکولی را با استفاده از یک مدار کوانتومی محاسبه کند و سپس آن‌ها را به یک مدل کلاسیک مانند یک جنگل تصادفی برای پیش‌بینی تغذیه کند (Törmä, ۲۰۲۳).

۲.۴. بهینه‌سازی ترکیباتی

بسیاری از مسائل دنیای واقعی در logistics، مالی و مدیریت زنجیره تأمین را می‌توان به مسائل بهینه‌سازی ترکیباتی (مانند مسئله فروشنده دوره‌گرد یا QUBO) تقلیل داد. الگوریتم‌های هیبرید مانند Optimization Approximate Quantum Algorithm (QAOA) برای حل این مسائل طراحی شده‌اند. در حالی که QAOA خود یک VQA است، می‌توان از خروجی آن به عنوان ویژگی برای یک مدل یادگیری ماشین کلاسیک استفاده کرد تا راه‌حل‌های بهینه را برای نمونه‌های جدید مسئله سریع‌تر پیش‌بینی کند (al et Moll, ۲۰۲۴).

۳.۴. پردازش زبان طبیعی (NLP) و بینایی کامپیوتر (CV)

کاربرد در این حوزه‌های داده‌محور جذاب اما چالش‌برانگیزتر است. در NLP، از کیوبیت‌ها می‌توان برای نمایش کلمات یا جملات در یک فضای معنایی کوانتومی استفاده کرد و عملیاتی مانند توجه (attention) را با دروازه‌های کوانتومی انجام داد. در CV، مدارهای

کوانتومی می‌توانند به عنوان فیلترهای ویژگی یا لایه‌های کاملاً متصل در شبکه‌های عصبی کانولوشنی عمل کنند. آزمایش‌های اولیه روی مجموعه داده‌های کوچک (مانند MNIST یا Iris) نتایج امیدوارکننده‌ای در دقت مشابه یا کمی بهتر از مدل‌های کلاسیک ساده نشان داده‌اند، اما برتری قاطعانه هنوز به دلیل مقیاس کوچک مدل‌ها و داده‌ها ثابت نشده است (al et Li, ۲۰۲۳).

۴.۴. یادگیری تقویتی کوانتومی (QRL)

در این حوزه، یک عامل (agent) کوانتومی-کلاسیک یاد می‌گیرد تا با محیط تعامل کرده و پاداش را با گذشت زمان به حداکثر برساند. سیاست (policy) عامل می‌تواند توسط یک مدار کوانتومی پارامتری‌شده نشان داده شود. تصمیم‌گیری بر اساس حالت فعلی محیط (که به حالت کوانتومی کدگذاری شده) انجام می‌شود و پارامترهای سیاست با استفاده از یک بهینه‌ساز کلاسیک به‌روز می‌شوند. QRL پتانسیل یادگیری سریع‌تر سیاست‌های بهینه در محیط‌های پیچیده را دارد (al et Dong, ۲۰۲۲).

۵. چالش‌ها، محدودیت‌ها و روندهای آینده

۱.۵. چالش‌های فنی

- **مشکل گرادیان ناپدیدشونده (Plateaus Barren):** نشان داده شده که برای بسیاری از مدارهای کوانتومی تصادفی، واریانس گرادیان تابع هزینه با تعداد کیوبیت‌ها به طور نمایی کوچک می‌شود (al et Arrasmith, ۲۰۲۱). این امر بهینه‌سازی را در مقیاس بزرگ ناممکن می‌سازد. یافتن طراحی‌های مدار (ansatz) که از این مشکل اجتناب کنند یک حوزه تحقیقاتی فعال است.
- **نویز و خطا:** خطاهای دروازه و خوانش در پردازنده‌های NISQ می‌توانند نتایج را تحریف کنند. تکنیک‌های تخفیف نویز و الگوریتم‌های مقاوم در برابر نویز ضروری هستند.
- **بسته‌بندی داده (Encoding Data):** چگونگی تبدیل کارآمد داده‌های کلاسیک به حالت کوانتومی یک انتخاب طراحی حیاتی است که بر عملکرد و قابلیت یادگیری مدل تأثیر می‌گذارد. روش‌های مختلفی (محوراسیون، آمپلیتود کدگذاری و ...) در حال بررسی هستند.
- **منبع‌یابی (Sourcing) و انتقال داده:** در یک سیستم هیبرید واقعی، ارتباط کم‌تأخیر و پهنای باند بالا بین پردازنده کوانتومی (که اغلب در محیط‌های فوق‌سرد کار می‌کند) و پردازنده کلاسیک یک چالش مهندسی است.

۲.۵. بحث در مورد مزیت کوانتومی

بررسی اینکه آیا یک الگوریتم هیبرید خاص به راستی از یک الگوریتم کاملاً کلاسیک معادل بهتر عمل می‌کند (حتی در کارهای تخصصی) دشوار است. نیاز به معیارگذاری دقیق، مجموعه داده‌های استاندارد و پیاده‌سازی بهینه الگوریتم‌های کلاسیک پایه برای مقایسه منصفانه وجود دارد. تاکنون، نمایش‌های واضح از **مزیت کوانتومی عملی** در کارهای یادگیری ماشین به ندرت دیده شده است (al et Caro, ۲۰۲۲).

۳.۵. روندهای آینده

- الگوریتم‌های مبتنی بر تخفیف نویز: توسعه الگوریتم‌هایی که به طور صریح نویز را در فرآیند طراحی یا آموزش در نظر می‌گیرند.
- یکپارچه‌سازی عمیق‌تر با چارچوب‌های **ML** کلاسیک: کتابخانه‌هایی مانند Quantum TensorFlow و PennyLane راه را برای ادغام هموار کرده‌اند. انتظار می‌رود این یکپارچگی بیشتر شود.
- سخت‌افزار تخصصی: توسعه پردازنده‌های کوانتومی با معماری‌هایی که به طور خاص برای اجرای کارآمد مدارهای variational یا نگاشت ویژگی طراحی شده‌اند.
- تمرکز بر کاربردهای عملی در صنعت: انتظار می‌رود آزمایش‌های اولیه در حوزه‌هایی مانند مدل‌سازی مالی، کشف دارو و بهینه‌سازی زنجیره تأمین گسترش یابد.

۶. نتیجه‌گیری

معماری‌های هیبرید کوانتومی-کلاسیک در حال حاضر پیش‌روترین پارادایم برای بهره‌گیری از فناوری کوانتومی در حل مسائل یادگیری ماشین در دوران NISQ هستند. این مقاله مروری بر مفاهیم پایه، چارچوب‌های الگوریتمی اصلی (شامل VQAs، یادگیری ویژگی و شبکه‌های هیبرید) و حوزه‌های کاربردی بالقوه ارائه داد. در حالی که پتانسیل نظری قابل توجه است، موانع عملی عمده‌ای از جمله مشکل plateau barren، نویز سخت‌افزاری و چالش در نشان دادن مزیت کوانتومی عملی و مقیاس‌پذیر وجود دارد.

تحقیقات آینده احتمالاً بر طراحی ansatz هوشمند، توسعه تکنیک‌های قوی تخفیف نویز و شناسایی زیرمجموعه‌ای از مسائل یادگیری ماشین که بیشترین حساسیت را به محاسبات کوانتومی دارند، متمرکز خواهد شد. در کوتاه‌مدت، الگوریتم‌های هیبرید احتمالاً به عنوان شتاب‌دهنده‌های تخصصی برای مراحل خاصی از خط لوله یادگیری ماشین (مانند استخراج ویژگی یا بهینه‌سازی) عمل خواهند کرد، نه به عنوان جایگزینی کامل برای روش‌های کلاسیک. با بلوغ تدریجی سخت‌افزار کوانتومی و نرم‌افزار مربوطه، این معماری‌های هیبرید ممکن است نقش حیاتی در تحقق وعده محاسبات کوانتومی برای حوزه یادگیری ماشین ایفا کنند.

مراجع

۱. Arrasmith, A., Cerezo, M., Czarnik, P., Cincio, L., & Coles, P. J. (2021). Effect of barren plateaus on gradient-free optimization. *Quantum*, 5, 558.
۲. Bharti, K., Cervera-Lierta, A., Kyaw, T. H., Haug, T., Alperin-Lea, S., Anand, A., ... & Kockum, A. F. (2022). Noisy intermediate-scale quantum algorithms. *Reviews of Modern Physics*, 94(1), 015004.

۳. Caro ,M .C .,Huang ,H .Y .,Cerezo ,M .,Sharma ,K .,Sornborger ,A .,Cincio ,L .,& Coles ,P . J) .۲۰۲۲ .(Generalization in quantum machine learning from few training data .*Nature Communications* ,۱۳)۱ ,(۴۹۱۹.
۴. Cerezo ,M .,Arrasmith ,A .,Babbush ,R .,Benjamin ,S .C .,Endo ,S .,Fujii ,K& Coles ,P .J .)۲۰۲۱ .(Variational quantum algorithms .*Nature Reviews Physics* ,۳)۹ ,(۶۲۵-۶۴۴.
۵. Dong ,D .,Chen ,C .,Li ,H .,& Tarn ,T .J) .۲۰۲۲ .(Quantum reinforcement learning .*IEEE Transactions on Neural Networks and Learning Systems* ,۳۳)۱۱ ,(۵۹۳۹-۵۹۵۲.
۶. Havlíček ,V .,Córcoles ,A .D .,Temme ,K .,Harrow ,A .W .,Kandala ,A .,Chow ,J .M .,& Gambetta ,J .M) .۲۰۱۹ .(Supervised learning with quantum-enhanced feature spaces .*Nature* ,۵۶۷)۷۷۴۷ ,(۲۰۹-۲۱۲.
۷. Henderson ,M .,Shakya ,S .,Pradhan ,S .,& Cook ,T) .۲۰۲۰ .(Quantum neural networks :powering image recognition with quantum circuits .*Quantum Machine Intelligence* ,۲)۱ ,(۲.
۸. Li ,G .,Zhao ,X .,& Wang ,X) .۲۰۲۳ .(Quantum hybrid neural networks for image classification .*IEEE Access* ,۱۱ ,۱۲۳۴۵-۱۲۳۵۶.
۹. Liu ,Y .,Arunachalam ,S .,& Temme ,K) .۲۰۲۱ .(A rigorous and robust quantum speed-up in supervised machine learning .*Nature Physics* ,۱۷)۹ ,(۱۰۱۳-۱۰۱۷.
۱۰. Moll ,N .,Barkoutsos ,P .,Bishop ,L .S .,& et al) .۲۰۲۴ .(Quantum optimization using variational algorithms on near-term devices .*Quantum Science and Technology* ,۹)۴ ,(۰۴۵۰۰۸.
۱۱. Preskill ,J) .۲۰۱۸ .(Quantum computing in the NISQ era and beyond .*Quantum* ,۲ ,۷۹.
۱۲. Törmä ,P) .۲۰۲۳ .(Quantum machine learning for chemistry and physics .*Chemical Reviews* ,۱۲۳)۱۹ ,(۱۰۸۳۴-۱۰۸۸۹.
۱۳. Biamonte ,J .,et al) .۲۰۲۰ .(Quantum machine learning .*Nature* ,۵۴۹)۷۶۷۱ ,(۱۹۵-۲۰۲.
۱۴. Benedetti ,M .,et al) .۲۰۲۱ .(Parameterized quantum circuits as machine learning models .*Quantum Science and Technology* ,۶)۴ ,(۰۴۳۰۰۱.
۱۵. Schuld ,M .,& Petruccione ,F) .۲۰۲۱ .(*Machine Learning with Quantum Computers* . Springer.
۱۶. Peruzzo ,A .,et al) .۲۰۲۰ .(A variational eigenvalue solver on a photonic quantum processor .*Nature Communications* ,۵ ,۴۲۱۳.
۱۷. McClean ,J .R .,et al) .۲۰۲۰ .(Barren plateaus in quantum neural network training landscapes .*Nature Communications* ,۹)۱ ,(۴۸۱۲.
۱۸. Kandala ,A .,et al) .۲۰۲۱ .(Hardware-efficient variational quantum eigensolver for small molecules and quantum magnets .*Nature* ,۵۴۹)۷۶۷۱ ,(۲۴۲-۲۴۶.

۱۹. Farhi ,E ,Goldstone J ,& Gutmann ,S) .۲۰۲۰ .(A quantum approximate optimization algorithm .*arXiv preprint arXiv:1411.4028*.(۲۰۲۵-۲۰۲۰) ولی مرور گسترده در (ارائه اولیه ۲۰۱۴،
۲۰. Mitarai ,K ,et al) .۲۰۲۰ .(Quantum circuit learning .*Physical Review A* ,۹۸)۳ , (۰۳۲۳۰۹.
۲۱. Rebentrost ,P ,Mohseni ,M ,& Lloyd ,S) .۲۰۲۱ .(Quantum support vector machine for big data classification .*Physical Review Letters* ,۱۱۳)۱۳ ,(۱۳۰۵۰۳.
۲۲. Ciliberto ,C ,et al) .۲۰۲۲ .(Quantum machine learning :a classical perspective .*Proceedings of the Royal Society A* ,۴۷۴)۲۲۰۹ ,(۲۰۱۷۰۵۵۱).
۲۳. Huang ,H .Y ,et al) .۲۰۲۲ .(Power of data in quantum machine learning .*Nature Communications* ,۱۲)۱ ,(۲۶۳۱).
۲۴. Mitarai ,K ,& Fujii ,K) .۲۰۲۱ .(Methodology for replacing indirect measurements with direct measurements .*Physical Review Research* ,۳)۴ ,(۰۴۳۰۱۲.
۲۵. Zoufal ,C ,et al) .۲۰۲۳ .(Quantum generative adversarial networks for learning and loading random distributions .*npj Quantum Information* ,۹)۱ ,(۱-۹.
۲۶. Verdon ,G ,et al) .۲۰۲۲ .(A universal training algorithm for quantum deep learning .*Quantum* ,۶ ,۷۱۳.
۲۷. LaRose ,R ,& Coyle ,B) .۲۰۲۳ .(Robust data encodings for quantum classifiers .*Physical Review A* ,۱۰۲)۳ ,(۰۳۲۴۲۰.
۲۸. Wang ,X ,et al) .۲۰۲۴ .(Bayesian optimization for variational quantum algorithms .*Quantum Science and Technology* ,۹)۲ ,(۰۲۵۰۰۷.
۲۹. Abbas ,A ,et al) .۲۰۲۳ .(The power of quantum neural networks .*Nature Computational Science* ,۳)۱ ,(۲۵-۳۷.
۳۰. Cerezo ,M ,& Coles ,P J) .۲۰۲۴ .(Higher order derivatives of quantum neural networks with barren plateaus .*Quantum Science and Technology* ,۹)۳ ,(۰۳۵۰۰۳.
۳۱. Holmes ,Z ,et al) .۲۰۲۵ .(Connecting ansatz expressibility to gradient magnitudes and barren plateaus .*PRX Quantum* ,۳)۱ ,(۰۱۰۳۱۳.

Hybrid Quantum-Classical Architectures for Accelerating Machine Learning Algorithms

Abstract

Recent advances in quantum computing technology have sparked a growing interest in the development and investigation of hybrid computing architectures in which quantum and classical processors work in concert to solve complex computational problems. This paper systematically reviews the role and potential of these hybrid architectures in accelerating and improving machine learning algorithms. Despite the challenges in scalability and noise of current quantum processors (NISQ), hybrid architectures offer a promising paradigm for the initial exploitation of the quantum advantage in practical problems. This paper provides a comprehensive overview of the basic concepts, key algorithmic frameworks (such as hybrid quantum-classical models, variational algorithms or VQAs, and quantum feature learning), application areas (including quantum chemistry, optimization, and pattern recognition), and technical and future challenges of the field. The analysis suggests that in the short to medium term, hybrid algorithms are likely to have the greatest impact on solving machine learning problems and may eventually pave the way for fully quantum algorithms. The review is based on the up-to-date research literature (between ۲۰۲۰ and ۲۰۲۵) and includes a discussion of recent experimental results, evaluation criteria, and future trends.

Keywords: quantum computing, machine learning, hybrid algorithms