



RSC813-3

دراسات نقدية 3

Task8

Prepared by

Mohammed Omar Bin Makhashen

242001540@st.midocean.edu.km

محمد عمر بن مخاشن

Ph.D. student in IT

2025-Apr-5

المحتوى

رسالة الدكتوراه

اختيار رسال دكتوراه في مجال QML

- التعريف بالبحث
- مقدمة
- النظرية 1: نظرية التعلم الإحصائي (SLT) في تطبيقها على QML
 - جانب القوة لاستخدام النظرية في البحث
 - جانب القصور مع **تحديد مواضعها** بالبحث
- كيف يمكن **الاستفادة في بحثي** الخاص للدكتوراه (التوصيات والابحاث المستقبلية)
- النظرية 2. نماذج الحوسبة الكمومية وافتراضاتها (qRAM, HHL, محاكاة الهاملتونيان)
- النظرية 3. الجبر الخطي العددي العشوائي (RandNLA) والخوارزميات المستوحاة من الكم
- النظرية 4. النماذج المستوحاة من الميكانيكا الإحصائية (مثل آلات بولتزمان الكمومية - QBMs)
- خاتمة

عنوان البحث: Quantum Machine Learning For Classical Data

(التعلم الآلي الكمي للبيانات الكلاسيكية)

الباحث: Leonard P. Wossnig

الدرجة العلمية: Doctor of Philosophy

الجامعة: University College London (UCL)

القسم: Department of Computer Science -

تاريخ التقديم: April 25, 2021

المجال العام للبحث:

تقاطع الحوسبة الكمومية والتعلم الآلي، وتحديدًا تطبيق الخوارزميات الكمومية على مهام التعلم الآلي الخاضع للإشراف التي تعمل على بيانات كلاسيكية

الأهداف الرئيسية للبحث:

- التحقيق في مدى قدرة أجهزة الكمبيوتر الكمومية على تسريع خوارزميات التعلم الآلي الخاضع للإشراف للبيانات الكلاسيكية.
- تطوير فهم واضح للعود والقيود الحالية لخوارزميات التعلم الآلي الكمي (QML) في هذا السياق.
- تحديد اتجاهات البحث المستقبلية في هذا المجال.
- تقييم أداء خوارزميات QML من منظور نظرية التعلم الإحصائي (SLT).
- تحليل تأثير نماذج الوصول إلى البيانات (مثل qRAM) ومقارنة الخوارزميات الكمومية مع الخوارزميات الكلاسيكية العشوائية (RandNLA).
- اقتراح مجالات واعدة لـ QML (مثل التعامل مع البيانات الكمومية) وتقديم مساهمات فيها (مثل خوارزمية لتدريب QBMs).

المنهجيات والأدوات الرئيسية المستخدمة:

- نظرية التعلم الإحصائي (SLT)
- الحوسبة الكمومية ونظرية المعلومات الكمومية (بما في ذلك خوارزميات محددة مثل HHL, QSVM, محاكاة الهاملتونيان)
- الجبر الخطي العددي العشوائي (RandNLA) (بما في ذلك طريقة نيستروم Nyström)
- نماذج مستوحاة من الميكانيكا الإحصائية (QBMs)
- التحليل الدالي للمصفوفات

تقييم نقدي لـ QML وامكانية الاستفادة لتطوير خوارزمية هجينة للبيانات الطبية

الهدف: تحليل نقدي لأطروحة (Wossnig, 2021) حول QML للبيانات الكلاسيكية للاستفادة منه في بحث هجين مقترح.

النقد المستخلص من الأطروحة:

- **حدود SLT والقياس:** متطلبات التعميم وتكاليف القياس الكمومي تحد من التسريع الأسّي المأمول لـ QML البحث.
- **افتراضات QML:** نماذج مثل qRAM صعبة التحقيق، والخوارزميات حساسة للمعاملات والضوضاء (NISQ).
- **تحدي RandNLA:** الخوارزميات الكلاسيكية "المستوحاة من الكم" ترفع مستوى المقارنة وتشكك في "كمومية" الميزة.
- **صعوبة QBMs:** تدريب النماذج التوليدية الكمومية مكلف ومعقد (خاصة إعداد حالة جيبس).

الاستنتاج والرؤية:

QML البحث للبيانات الكلاسيكية يواجه تحديات كبيرة. اما عن نهج الخوارزميات الهجينة يمثل مسارا اكثر واقعية

بحثي المقترح:

تطوير خوارزمية هجينة (كمي-كلاسيكي) لتحليل البيانات الطبية، تستغل المزايا الكمومية بشكل جيد مع تجنب الاختناقات المعروفة، وتركز على الأداء الفعال والتعميم الجيد.

1. نظرية التعلم الإحصائي (SLT) في تطبيقها على QML

1. الاعتراف بأهمية وقوة SLT :

- تعد نظرية التعلم الإحصائي (SLT) [44, 47] حجر الزاوية في فهمنا للتعلم الآلي الكلاسيكي، حيث توفر إطارًا رياضيًا صارمًا لتحليل قدرة الخوارزميات على التعميم من بيانات التدريب المحدودة إلى بيانات جديدة غير مرئية. مفاهيمها الأساسية، مثل تقليل المخاطر التجريبية (ERM)،
- حدود خطأ التعميم (المعتمدة على تعقيد فضاء الفرضية)، ومعدلات التعلم، ضرورية لتقييم أي خوارزمية تعلم تتجاوز مجرد الأداء على مجموعة التدريب. إن تطبيق هذا الإطار على التعلم الآلي الكمي (QML)، كما تم البدء به في [177, 178] وتم تحليله بعمق في الفصل الثالث من هذه الأطروحة [25]، يمثل خطوة حاسمة نحو تقييم واقعي للوعود التي تقدمها الخوارزميات الكمومية في هذا المجال. فبدون ضمانات التعميم، يظل التسريع الحسابي النظري للخوارزميات الكمومية ذا قيمة عملية محدودة.

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من البحث):

- أ. تجاهل SLT القياسية لتكاليف الوصول الكمومي والقياس:
- "أحد الانتقادات الجوهرية لتطبيق SLT القياسية مباشرة على العديد من خوارزميات QML المقترحة هو أنها غالبًا ما تتجاهل التكاليف الحاسمة المرتبطة بالواجهة الكمومية-الكلاسيكية. كما أوضحت الأطروحة في الفصلين 3 و 4 [23, 24, 25, 56]، فإن العديد من خوارزميات QML تفترض وجود آليات فعالة (مثل [6] qRAM) لتحميل البيانات الكلاسيكية إلى حالات كمومية، وهو افتراض قوي جدًا ذو تكاليف عملية ونظرية غير محسومة [72, 74, 75]. الأهم من ذلك، وكما تم تحليله بالتفصيل في القسم 3.3.2 [25] (والمعادلات 3.31-3.36)، فإن استخراج النتائج الكلاسيكية من الحالة الكمومية النهائية **يتطلب قياسات متكررة**، مما يضيف خطأ (يتبع)

1. نظرية التعلم الإحصائي (SLT) في تطبيقها على QML (استكمال)

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من الأطروحة): (استكمال)

- أ. تجاهل SLT القياسية لتكاليف الوصول الكمومي والقياس:

"أحد الانتقادات الجوهرية لتطبيق SLT القياسية على العديد من خوارزميات QML المقترحة هو أنها غالبًا ما تتجاهل التكاليف الحاسمة المرتبطة بالواجهة الكمومية-الكلاسيكية. كما أوضحت الأطروحة في الفصلين 3 و 4 [23, 24, 25, 56]، فإن العديد من خوارزميات QML تفترض وجود آليات فعالة (مثل [6] qRAM) لتحميل البيانات الكلاسيكية إلى حالات كمومية، وهي افتراضية جيدة ولكن تكاليف عملية ونظرية غير محسومة [72, 74, 75]. الأهم من ذلك،

وكما تم تحليله بالتفصيل في القسم 3.3.2 [25] (والمعادلات 3.31-3.36)، فإن استخراج النتائج الكلاسيكية من الحالة الكمومية النهائية يتطلب قياسات متكررة، مما يضيف خطأ إحصائيًا (Shot Noise) يتناسب عكسيًا مع الجذر التربيعي لعدد القياسات (أو بشكل أفضل قليلًا مع القياسات المتقدمة). عندما يتم دمج هذا الخطأ الإحصائي الضروري مع متطلبات SLT بأن خطأ التحسين الكلي يجب ألا يتجاوز خطأ التعميم (الذي يتناسب غالبًا مع $n\sqrt{1}$ كما في المعادلة 3.13)، فإن هذا يؤدي حتمًا، كما هو موضح في المعادلات 3.30 و 3.35، إلى اعتماد متعدد الحدود على حجم العينة n في التعقيد الزمني الكلي، وهذا للاسم يلغي الادعاء ويقوض بشكل كبير ادعاءات التسريع الأسّي لـ QML للبيانات الكلاسيكية في ظل متطلبات التعميم القياسية (الخلاصة في القسم 3.5 والشكل 3.1).

1. نظرية التعلم الإحصائي (SLT) في تطبيقها على QML (استكمال)

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من الأطروحة): (استكمال)

- **ب. عدم كفاية مقاييس التعقيد الكلاسيكية لفضاءات الميزات الكمومية:**

"تعتمد حدود التعميم في SLT بشكل كبير على مقياس لتعقيد فضاء الفرضية (Hypothesis Space)، مثل بُعد VC أو تعقيد Rademacher [44, 47]. بينما تم استخدام هذه المقاييس بشكل ضمني في الأطروحة (عبر $c(H)$ في المعادلة 3.13)، فإن هناك تساؤلًا مفتوحًا (أشير إليه في ص 151) حول مدى كفايتها لوصف التعقيد الفعلي لفضاءات الفرضيات التي تنشأ في QML، خاصة تلك التي تستخدم فضاءات الميزات الكمومية (Quantum Feature Spaces) أو الأنوية الكمومية [152, 178]. قد تمتلك هذه الفضاءات، التي تستغل فضاء هيلبرت الهائل، خصائص (مثل التعبيرية العالية جدًا أو ربما "بنية" كامنة مفيدة) لا تلتقطها مقاييس التعقيد الكلاسيكية بشكل كامل."

- **ج. حدود افتراضات البيانات (مثل i.i.d.):** (هذا الجانب لم يتم التركيز عليه بشكل كبير في البحث ولكنها ملاحظة عامة لـ SLT في التطبيقات المعقدة).

"تعتمد العديد من نتائج SLT القياسية، بما في ذلك التحليلات التي تستند إليها الأطروحة بشكل عام (كما هو مذكور في الافتراض 2، ص 33)، على افتراض أن بيانات التدريب هي عينات مستقلة وموزعة بشكل مماثل (i.i.d.). بينما يمكن تمديد SLT للتعامل مع بعض التبعية الضعيفة (Mixing Conditions)، فإن العديد من مجموعات البيانات الواقعية، وخاصة في المجال الطبي، تظهر تبعيات أكثر تعقيدًا (بيانات طولية، علاقات بين المرضى، تجميعات مكانية). قد يوفر QML، نظريًا، أدوات جديدة (مثل نماذج الموتر Tensor Networks أو QBMs) لنمذجة هذه التبعية المعقدة بطرق قد لا تكون سهلة ضمن إطار SLT الكلاسيكي. إن تقييم أداء QML في ظل هذه الافتراضات الأكثر واقعية للبيانات يمثل تحديًا ومنطقة بحثية مهمة لم يتم استكشافها بالكامل بعد."

1. نظرية التعلم الإحصائي (SLT) في تطبيقها على QML (استكمال)

4. ربط النقد النظرية بالبحث (التوصيات والابحاث المستقبلية) والاستفادة في بحثك:

"إن هذا النقد الموجه لكفاية SLT القياسية في سياق QML هو الذي شكل الدافع الرئيسي للفصل الثالث من البحث والذي قام بتحليل صارم لتأثير متطلبات التعميم (خاصة معدل التعلم $O(1/\sqrt{n})$) وخطأ القياس على التعقيد الزمني لخوارزميات QML للبيانات الكلاسيكية، مما أدى إلى استنتاج مفاده أن التسريع الأسّي غير مرجح في هذا الإطار.

بالنسبة لبحثي حول الخوارزمية الهجينة لتحليل البيانات الطبية:

- **تبرير النهج الهجين:** القيود التي تفرضها SLT على QML البحث (خاصة عند الحاجة إلى مخرجات كلاسيكية دقيقة مع تعميم جيد) تجعل النهج الهجين، الذي يجمع بين أفضل ما في العالمين، خيارًا أكثر واقعية وواعدًا لتحقيق فائدة عملية.
- **التركيز على التعميم في التصميم:** يجب أن يكون تحسين قدرة الخوارزمية الهجينة على التعميم للبيانات الطبية غير المرئية هو الهدف الأساسي، وليس مجرد السعي وراء تسريع حسابي نظري في الجزء الكومومي. يجب تحليل كيف يؤثر التكامل الهجين على حدود التعميم.
- **تحليل المقايضات:** يجب أن يحل تصميم الخوارزمية المقايضة بين الدقة الإحصائية (المستمدة من SLT)، والدقة الحسابية (خطأ التقريب في الأجزاء الكلاسيكية والكومومية)، وتكلفة الموارد (الكلاسيكية والكومومية، بما في ذلك القياسات).
- **ملاءمة السياق الطبي:** يجب تقييم ما إذا كانت افتراضات SLT القياسية (مثل i.i.d.) تنطبق على البيانات الطبية المستخدمة، واستكشاف كيف يمكن للنهج الهجين (ربما بمساعدة المكون الكومومي) التعامل بشكل أفضل مع التعقيدات والتحديات الفريدة لهذه البيانات (مثل الأبعاد العالية أو التبعية).

2. نماذج الحوسبة الكمومية وافتراضاتها (qRAM، HHL ، محاكاة

الهاملتونيان):

1. الاعتراف بأهمية وقوة النماذج الكمومية:

"شكلت الخوارزميات الكمومية الأساسية مثل خوارزمية HHL لحل الأنظمة الخطية [36] ومحاكاة الهاملتونيان [8, 79-92] نقطة انطلاق للعديد من الأفكار الواعدة في التعلم الآلي الكمي (QML). تعتمد هذه الخوارزميات على قدرات الحوسبة الكمومية الفريدة، مثل التراكب والتشابك، لمعالجة المعلومات بطرق تختلف جذريًا عن الحوسبة الكلاسيكية. نظريًا، تقدم هذه الخوارزميات إمكانية تحقيق تسريع كبير (غالبًا لوغاريتمي في أبعاد البيانات) لمهام جبر خطي أساسية تكمن في قلب العديد من تطبيقات التعلم الآلي [13, 14, 38-42]. غالبًا ما يتم تعزيز هذه الكفاءة النظرية من خلال افتراض نماذج وصول قوية للبيانات مثل ذاكرة الوصول العشوائي الكمومية (qRAM) [6, 7, 16]، والتي تعد بتحميل البيانات الكلاسيكية بكفاءة إلى حالات كمومية."

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من البحث):

- أ. تحدي واجهة البيانات (qRAM كافتراض وليس كواقع):

"يظل افتراض وجود qRAM فعالة وقابلة للتطوير أحد أكبر التحديات التي تواجه التطبيق العملي للعديد من خوارزميات QML، وهو نقد متكرر في المراجعة الأدبية [43, 72] تم التأكيد عليه في هذه الأطروحة. القسم 4.2.2 يناقش qRAM، بينما تشير الصفحات 66 و 127 إلى التحديات الكبيرة المرتبطة ببنائها المادي، وتكاليفها الهائلة، وحساسيتها للضوضاء [74, 75]. **إن الاعتماد الأساسي على qRAM للحصول على تسريع لوغاريتمي يضعف من الادعاءات المتعلقة بالتفوق الكمومي، خاصة (يتبع)**

2. نماذج الحوسبة الكمومية وافتراضاتها (qRAM، HHL ، محاكاة الهاملتونيان): (استكمال)

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من البحث): (استكمال)

- أ. تحدي واجهة البيانات (qRAM كافتراض وليس كواقع):

"... وتكاليفها الهائلة، وحساسيتها للضوضاء [74, 75]. إن الاعتماد الاساسي على qRAM للحصول على تسريع لوغاريتمي يضعف من الادعاءات المتعلقة بالتفوق الكمومي، خاصة وأن الأطروحة أظهرت في الفصل الرابع (وخاصة في سياق الخوارزميات المستوحاة من الكم 4.2.3 و 4.4.7) أنه يمكن تحقيق كفاءات مماثلة (من حيث استقلالية الأبعاد) باستخدام نماذج وصول كلاسيكية قوية مماثلة (Sample and Query Access)".

- ب. استخراج المعلومات الكلاسيكية (تكلفة ودقة القياس):

"حتى مع وجود qRAM والحساب الكمومي الفعال، تظل مشكلة استخراج النتيجة الكلاسيكية قائمة. كما هو مبين في القسم 3.3.2 (Sampling Error)، فإن القياس الكمومي عملية احتمالية بطبيعتها وتتطلب تكرارات متعددة لتحقيق دقة إحصائية مقبولة (تقليل خطأ Shot Noise). هذه التكلفة تتناسب عكسيًا مع مربع الدقة المطلوبة ($\epsilon^2/1$) في الحالة القياسية، أو $\epsilon/1$ باستخدام تقدير السعة (Amplitude Estimation) [179] (المذكور في الملحق A.1). هذه التكلفة، عند دمجها مع متطلبات الدقة المستمدة من SLT (كما في القسم 3.3.1)، تساهم بشكل كبير في التعقيد الكلي وتحد من الميزة الكمومية، كما هو موضح في الاستنتاجات النهائية لتعقيد QML في الشكل 3.1.

2. نماذج الحوسبة الكمومية وافتراضاتها (qRAM، HHL ، محاكاة الهاملتونيان): (استكمال)

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من البحث): (استكمال)

- ج. الاعتماد على معلومات المشكلة (مثل K وتشتت H):

"لا يعتمد أداء الخوارزميات الكمومية فقط على أبعاد البيانات، بل في الغالب يعتمد بشكل أساسي على خصائص أخرى للمشكلة. خوارزمية HHL، على سبيل المثال، تتأثر بشدة برقم شرط المصفوفة K (القسم 3.3.3، 4.4.4). خوارزميات محاكاة الهاملتونيان التقليدية تتأثر بتشتت (Sparsity) الهاملتونيان [90] s (القسم 4.4.1، 4.4.2). بينما يقدم البحث تحليلاً للخوارزميات التي تتعامل مع الهاملتونيات الكثيفة (القسم 4.4.4)، غالباً ما تأتي هذه التحسينات على حساب الاعتماد على معايير (Norms) أخرى أو افتراضات وصول أقوى للبيانات. إن عدم وجود طرق فعالة للتعامل مع المصفوفات سيئة التكييف (ص 38، 57) أو غير المتفرقة بدون افتراضات قوية يحد من قابلية تطبيق هذه الخوارزميات على نطاق واسع."

- د. قيود أجهزة العصر الحالي (NISQ - الضوضاء والعمق المحدود):

"تم تصميم معظم هذه الخوارزميات الكمومية مع افتراض وجود حواسيب كمومية مثالية أو قادرة على تصحيح الأخطاء. الواقع الحالي لأجهزة NISQ تحد الضوضاء وفقدان الترابط من حجم وعمق الدوائر التي يمكن تنفيذها بموثوقية (تمت الإشارة إليه بشكل عام كم مشكلة عملية، ص 152، 154). هذا يعني أن التعقيدات النظرية المقاربة قد لا تترجم إلى أداء فعلي، وأن الخوارزميات التي تتطلب موارد كبيرة (مثل عدد كبير من الكيوبتات أو البوابات المتشابكة أو القياسات التكميلية) قد تكون غير عملية في المدى البعيد."

2. نماذج الحوسبة الكمومية وافتراضاتها (qRAM، HHL ، محاكاة الهاملتونيان): (استكمال)

3. الاستفادة من النقد في بحثي حول الخوارزمية الهجينة لتحليل البيانات الطبية:

- **تجنب الاختناقات:** ميزة تصميم الخوارزمية الهجينة انها تتجنب الاختناقات الرئيسية المتمثلة في qRAM واسعة النطاق والقياسات التوموغرافية المكلفة. سيتم التعامل مع الجزء الأكبر من البيانات والنتائج النهائية بواسطة المكون الكلاسيكي.
- **دور كمومي مستهدف:** سيتم تكليف الجزء الكمومي بمهام محددة حيث قد تكمن ميزة محتملة تتجاوز مجرد حل الأنظمة الخطية أو المحاكاة العامة، مثل استغلال فضاء الميزات الكمومي لإنشاء تمثيلات غير خطية للبيانات الطبية التي قد تكون معقدة بطبيعتها.
- **الوعي بتكاليف NISQ:** سيتم تصميم الجزء الكمومي ليكون قابلاً للتنفيذ على أجهزة NISQ، مع مراعاة العمق المحدود للدائرة وتأثير الضوضاء المحتمل، وربما دمج تقنيات تخفيف الأخطاء كجزء من الخوارزمية.
- **قياس الأداء الشامل:** لن يتم تقييم الخوارزمية الهجينة فقط بناءً على التعقيد النظري للجزء الكمومي، ولكن بناءً على الأداء العام للنظام الهجين (الدقة، التعميم، زمن التشغيل الفعلي، استهلاك الموارد) ومقارنته بخطوط الأساس الكلاسيكية القوية (بما في ذلك RandNLA).

3. الجبر الخطي العددي العشوائي (RandNLA) والخوارزميات المستوحاة من الكم:

1. الاعتراف بأهمية وقوة RandNLA (تحديد نقاط القوة):

"حصل مجال الجبر الخطي العددي العشوائي (RandNLA) في السنوات الأخيرة، أصبح لدينا مجموعة كبيرة من التقنيات القائمة على أخذ العينات (Sampling) والإسقاطات العشوائية (Random Projections) لمعالجة مشاكل الجبر الخطي واسعة النطاق بكفاءة غير مسبوقة [69, 71].

خوارزميات مثل ضرب المصفوفات العشوائي [70] (تم شرحه في القسم 4.3)، وطريقة نيستروم لتقريب المصفوفات منخفضة الرتبة [54, 107-109] (تم شرحها في القسم 4.4.5 واستخدامها في 4.4.5)، وتقنيات الانحدار العشوائي [102]، أصبحت أدوات لا غنى عنها في التعلم الآلي الكلاسيكي ومعالجة البيانات الضخمة. الأهم من ذلك، في سياق التعلم الآلي الكمي (QML)،

وكما تم استكشافه بعمق في الفصل الرابع من هذا البحث لعبت RandNLA دورًا محوريًا في فهم حدود الادعاءات المتعلقة بالتسريع الكمومي. فقد أدى ظهور الخوارزميات "المستوحاة من الكم" (Quantum-Inspired Algorithms) [15, 17-21] تمت مناقشتها في 4.2.3، 4.4.2، 4.4.7، والخاتمة)، والتي تستخدم تقنيات RandNLA لمحاكاة أو تجاوز أداء بعض خوارزميات QML تحت افتراضات وصول مشابهة للبيانات (Sample and Query Access)، إلى إعادة تقييم جوهرية للميزة الكمومية المفترضة."

3. الجبر الخطي العددي العشوائي (RandNLA) والخوارزميات المستوحاة من الكم: (استكمال)

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من البحث):

- أ. الطبيعة التقريبية والضمانات الاحتمالية:

"بطبيعتها، تنتج خوارزميات RandNLA حلولاً تقريبية، وتأتي ضماناتها عادةً في شكل حدود احتمالية (أي أن الحل يكون جيدًا باحتمالية عالية) [69]. بينما تكون هذه الضمانات كافية للعديد من تطبيقات التعلم الآلي، إلا أنها قد لا تكون مناسبة لجميع السيناريوهات، خاصة تلك التي تتطلب دقة عالية مضمونة. علاوة على ذلك، فإن الثوابت المخفية في حدود الخطأ والتعقيد قد تكون كبيرة في بعض الأحيان، مما يؤثر على الأداء العملي مقارنةً بالتحليل النظري المقارب (تمت الإشارة إليه ضمناً عند مناقشة الحاجة إلى معايير عملية في 127-129, 154)."

- ب. الاعتماد على بنية البيانات (خاصة الرتبة المنخفضة):

"الكثير من النجاحات البارزة لـ RandNLA، وخاصة طريقة نيستروم والخوارزميات المستوحاة من الكم، تعتمد بشكل كبير على افتراض أن البيانات الأساسية (أو المصفوفات التي تمثلها) لها بنية منخفضة الرتبة (Low-Rank) أو شبه منخفضة الرتبة [54, 17]. كما ذكر في الأطروحة (ص 80, 85, 105)، قد لا يكون هذا الافتراض صحيحاً دائماً للبيانات الطبية المعقدة أو لمشاكل أخرى في العالم الحقيقي. عندما تفشل هذه الافتراضات، قد يتدهور أداء خوارزميات RandNLA بشكل كبير، مما قد يفتح نافذة محتملة للتفوق الكمومي إذا كانت الخوارزميات الكمومية أقل حساسية لهذه الافتراضات البنيوية."

3. الجبر الخطي العددي العشوائي (RandNLA) والخوارزميات المستوحاة من الكم: (استكمال)

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من البحث): (استكمال)

- ج. تحديدات اختيار التقنية والمعاملات: (اقصد وضع معايير)

"يقدم مجال RandNLA مجموعة واسعة من التقنيات، ولكل منها مقابل الخاصة بين السرعة والدقة والافتراضات. اختيار التوزيع الاحتمالي المناسب لأخذ العينات (Sampling Distribution)، أو تحديد عدد العينات أو أبعاد الإسقاط (Number of Samples/Projection Dimension)، أو حتى اختيار نوع التقريب (مثل Nyström مقابل Random Features [135]) يمكن أن يكون له تأثير كبير على الأداء ويتطلب فهمًا عميقًا لكل من النظرية والبيانات [71]."

- د. حدود المقارنة المباشرة مع QML:

- "بينما تُعد المقارنة مع RandNLA والخوارزميات المستوحاة من الكم ضرورية، إلا أنها لا تخلو من الصعوبات.
- أولاً، غالبًا ما يتم تقييم التعقيد الكمومي باستخدام نموذج الاستعلام (Query Model) لـ qRAM، بينما تقيّم RandNLA غالبًا باستخدام نموذج المرور (Pass-Efficient Model) أو نماذج وصول أخرى [69] (تمت مناقشة هذه النماذج في القسم 4.2). مقارنة التعقيدات عبر هذه النماذج المختلفة تتطلب حذرًا.
- ثانياً، قد تستغل الخوارزميات الكمومية أنواعًا أخرى من البنية (مثل التشتت Sparse Structure في HHL الأصلي) أو القدرات (مثل توليد تراكبات معقدة) التي لا يمكن لـ RandNLA محاكاتها بسهولة.
- ثالثاً، تختلف طبيعة الأخطاء؛ خطأ RandNLA هو خطأ تقريبي في الخوارزمية نفسها، بينما يضاف إلى خطأ الخوارزمية الكمومية خطأ القياس الإحصائي."

3. الجبر الخطي العددي العشوائي (RandNLA) والخوارزميات المستوحاة من الكم: (استكمال)

3. الاستفادة من النقد في بحثك حول الخوارزمية الهجينة لتحليل البيانات الطبية:

- **تحديد المعيار الذهبي الكلاسيكي:** يجب أن تُقارن الخوارزمية الهجينة بأحدث وأنسب تقنيات RandNLA (مثل طرق النواة العشوائية السريعة، أو طرق نيستروم المحسنة، أو [10] FALKON إذا كانت المشكلة تتضمن طرق النواة) التي تعالج نفس المهمة على البيانات الطبية. هذا يضمن أن أي ادعاء بالميزة لا يأتي على حساب مقارنة غير عادلة.
- **الاستفادة من RandNLA في المكون الكلاسيكي:** يمكن دمج تقنيات RandNLA بشكل فعال في الجزء الكلاسيكي من الخوارزمية الهجينة. على سبيل المثال، يمكن استخدام أخذ العينات لتقليل حجم مصفوفة النواة (Kernel Matrix) قبل معالجتها ربما بواسطة جزء كمومي، أو استخدام مُحسِّنات (Optimizers) عشوائية مستوحاة من RandNLA لتسريع عملية التدريب الكلاسيكية.
- **تقييم افتراضات بنية البيانات:** قبل تطبيق الجزء الكمومي، يجب تحليل البيانات الطبية لتقييم مدى صحة افتراضات مثل الرتبة المنخفضة. إذا كانت البيانات منخفضة الرتبة بالفعل، فيجب أن يكون مبرر استخدام الجزء الكمومي قويًا جدًا (مثل تحقيق دقة أعلى بكثير لنفس التكلفة، أو استغلال بنية أخرى)، لأن RandNLA قد تكون فعالة للغاية بالفعل.
- **التركيز الكمومي على "ما بعد RandNLA":** يجب أن يركز الجزء الكمومي من الخوارزمية الهجينة على المهام أو أنواع البنية التي تمثل تحديًا لـ RandNLA. هل يمكن لكم استكشاف علاقات غير خطية معقدة جدًا، أو التعامل مع بيانات عالية الأبعاد بدون بنية منخفضة الرتبة واضحة، أو نمذجة أنواع معينة من الضوضاء أو التبعية بطريقتهم أفضل؟
- **الجمع بين التقريبيين:** يجب تحليل كيفية تفاعل الخطأ التقريبي الناتج عن RandNLA (في الجزء الكلاسيكي) مع الخطأ التقريبي والقياسي في الجزء الكمومي، وتأثير ذلك على الأداء الكلي للخوارزمية الهجينة.

. النماذج المستوحاة من الميكانيكا الإحصائية (مثل آلات بولتزمان الكمومية - QBMs) :

1. الاعتراف بأهمية وقوة QBMs :

"تقدم آلات بولتزمان الكمومية (QBMs) [151, 156, 158]، كامتداد كمومي لنظيرتها الكلاسيكية المستوحاة من الميكانيكا الإحصائية [160, 161]، إطاراً نظرياً جديداً للتعلم غير الخاضع للإشراف والنمذجة التوليدية للحالات الكمومية أو التوزيعات الاحتمالية الكلاسيكية المعقدة. من خلال ترميز التوزيع المستهدف في الحالة الحرارية (حالة جيبس) لهاملتونيان قابل للتدريب، تستفيد QBMs نظرياً من القدرة التمثيلية الهائلة لفضاءات هيلبرت والارتباطات الكمومية (التشابك) لنمذجة توزيعات **قد تكون صعبة على النماذج الكلاسيكية ذات الحجم المماثل** [163]. كما أن بنيتها المستوحاة مباشرة من الهاملتونيات تجعلها مناسبة بشكل طبيعي للمحاكاة على أجهزة الكمبيوتر الكمومية [157]. مساهمات حديثة، بما في ذلك تلك المقدمة في الفصل الخامس من هذا البحث [26]، حاولت معالجة التحديات الكبيرة في **تدريب هذه النماذج، خاصة في وجود وحدات مخفية وباستخدام مقاييس مناسبة** مثل الإنتروبيا النسبية الكمومية."

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من البحث) :

- أ. صعوبة تدريب QBMs (خاصة مع الوحدات المخفية) :

يمثل	تدريب	QBMs	تحدياً
هائلاً، وهو القصور الرئيسي الذي يعيق تطبيقها على نطاق واسع. كما تم تحليله في مقدمة الفصل الخامس وفي القسمين 5.3.1 و 5.3.2 [26]، تنبع الصعوبة الأساسية من الحاجة إلى حساب أو تقدير كميات مثل دالة التجزئة $Z = \text{Tr}(e^{-H})$ أو تدرجات دوال الهدف (مثل الإنتروبيا النسبية الكمومية $S(\rho \sigma_v) = \text{Tr}(\rho \log \rho) - \text{Tr}(\rho \log \sigma_v)$). (يتبع ..)			

4 . النماذج المستوحاة من الميكانيكا الإحصائية (مثل آلات بولتزمان الكمومية -

(QBMs): (استكمال)

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من البحث): (استكمال)

- أ. صعوبة تدريب QBMs (خاصة مع الوحدات المخفية):

"يمثل تدريب QBMs تحديًا هائلًا، وهو القصور الرئيسي الذي يعيق تطبيقها على نطاق واسع. كما تم تحليله في مقدمة الفصل الخامس وفي القسمين 5.3.1 و 5.3.2 [26]، تنبع الصعوبة الأساسية من الحاجة إلى حساب أو تقدير كميات ... في وجود وحدات مخفية، يتطلب حساب $\sigma_v = \text{Tr}_h(e^{-H/Z})$ أثرًا جزئيًا مكلفًا حسابيًا. بالإضافة إلى ذلك، فإن حساب σ_v و $\log$ أو تدرجه معقد للغاية بسبب عدم تبادلية المؤثرات، مما يتطلب تقنيات متقدمة مثل تلك القائمة على التقريب المتغيري أو الفروق المقسمة التي طورتها البحث في بحثه [26] (انظر الخوارزميات 5 و 6 والتحليلات في الملاحق B.2 و B.3). حتى مع هذه التقنيات الجديدة، تظل عملية التدريب مكلفة حسابيًا."

- ب. الاعتماد على افتراض كفاءة إعداد حالة جيبس (Gibbs State Preparation):

"تعتمد العديد من خوارزميات تدريب QBM المقترحة، بما في ذلك تلك الموجودة في الأطروحة [26] (كما هو مذكور في ص 135، 140، والنظريات 12 و 13 التي تعتمد على نظرية 15)، بشكل أساسي على القدرة على إعداد حالة جيبس الكمومية $(e^{-H/Z})$ للهاملتونيان H (أو H_h الفعال) بكفاءة. ومع ذلك، فإن إعداد حالة جيبس هو في حد ذاته مشكلة صعبة بشكل عام (QMA-hard لبعض الهاملتونيات [181]) وقد يتطلب موارد كمومية كبيرة أو زمنيًا طويلًا، خاصة عند درجات الحرارة المنخفضة (المقابلة للهاملتونيات ذات الفجوات الطاقية الصغيرة). هذا الافتراض، وإن كان شائعًا في المراجعات الأدبية يمثل عنق زجاجة أمام التطبيق العملي لـ QBMs (الاعتراف بهذا القصور في ص 135 و 147)."

4 . النماذج المستوحاة من الميكانيكا الإحصائية (مثل آلات بولتزمان الكمومية - QBMs):

(استكمال)

2. تحديد جوانب القصور والحدود (النقد المحدد والمدعوم بالأدلة من البحث): (استكمال)

- ج. مشاكل التقارب وأخذ العينات:

"إذا اعتمد التدريب على أخذ العينات (سواء لمحاكاة التلدين الكمومي أو لتقدير قيم التوقع)، فقد تواجه العملية مشاكل التقارب البطيء أو الخلط البطيء، مشابهة لتلك التي تواجه آلات بولتزمان الكلاسيكية، خاصة إذا كان مشهد الطاقة معقداً [160]. قد تتفاقم هذه المشكلة في السياق الكمومي."

- د. قابلية التوسع ومتطلبات أجهزة NISQ:

"إن الجمع بين صعوبة التدريب، والحاجة المحتملة لموارد كمومية كبيرة (لإعداد حالة جيبس أو لتشغيل الدوائر العميقة)، والحساسية الكبيرة للضوضاء في أجهزة NISQ الحالية، يجعل قابلية توسيع QBMs لتكون قادرة على نمذجة توزيعات بيانات واقعية ومعقدة (مثل تلك الموجودة في المجال الطبي) أمراً غير مؤكد إلى حد كبير في المستقبل القريب (كما أشير في ص 147 و 153)."

3. الاستفادة من النقد في بحثك حول الخوارزمية الهجينة لتحليل البيانات الطبية:

- تجنب تدريب QBMs كاملة للبيانات الطبية: نظراً لصعوبة التدريب وقابلية التوسع، من غير المرجح أن يكون تدريب QBM بحث لنمذجة التوزيع الكامل للبيانات الطبية المعقدة فعالاً في المدى القريب. هذا يعزز مبررات استخدام نهج هجين. (..يتبع)

4 . النماذج المستوحاة من الميكانيكا الإحصائية (مثل آلات بولتزمان الكمومية - QBM):

(استكمال)

3. الاستفادة من النقد في بحثي حول الخوارزمية الهجينة لتحليل البيانات الطبية: (استكمال)

- إمكانية استخدام QBM كمكون في النظام الهجين: بدلاً من استخدامها كنموذج توليدي كامل، يمكن استخدام QBM (ربما مدربة مسبقاً على بيانات أبسط أو بطريقة غير خاضعة للإشراف) كـ
- مهيب (Initializer): لتوفير نقطة بداية جيدة لتدريب نموذج هجين آخر.
- مستخرج ميزات كمومية: الحالة الحرارية لـ QBM (بعد تهميش الوحدات المخفية) يمكن أن توفر تمثيلاً كاملاً غنياً للبيانات يتم إدخاله بعد ذلك إلى نموذج كلاسيكي.
- جزء من نموذج توليدي هجين: يمكن دمج QBM صغيرة لنمذجة جوانب معينة من البيانات يصعب على النموذج الكلاسيكي التقاطها (مثل GAN أو VAE).
- الوعي بافتراضات التكلفة: إذا تم استخدام مكون يعتمد على QBM، يجب أن يكون التقييم واقعياً بشأن تكلفة إعداد حالة جيبس أو أي روتينات فرعية أخرى مطلوبة، وعدم تجاهل هذه التكاليف عند مقارنة الأداء بالبدايل الكلاسيكية.
- البحث عن بدائل كمومية للنمذجة التوليدية: قد يكون من المفيد استكشاف نماذج توليدية كمومية أخرى أقل متطلبات من QBM، مثل الدوائر الكمومية المتغيرة المصممة خصيصاً للمهام التوليدية (Quantum Circuit Born Machines, QCBMs) أو النسخ الكمومية لـ GANs، ودمجها في الإطار الهجين.
- الاستفادة من الارتباطات: إذا كانت البيانات الطبية تظهر ارتباطات معقدة عالية الرتبة، فقد تكون البنية الكامنة لـ QBM (حتى لو لم يتم تدريبها بالكامل) مصدر إلهام لتصميم مكونات (كمومية أو كلاسيكية) قادرة على التقاط هذه الارتباطات في النموذج الهجين.

ختاماً، تم نقد لأسس التعلم الآلي الكمي (QML) للبيانات الكلاسيكية، مستفيدين من رؤى بحث الدكتور. ووسنيغ. كشف النقد عن تحديات جوهرية في QML البحث تتعلق بمتطلبات التعميم (SLT)، وجدوى نماذج الكمبيوتر الكمومي وافترضاياته (qRAM، الضوضاء)، وقوة المقارنات مع RandNLA، وصعوبات تدريب النماذج التوليدية (QBMs). هذه التحديات مجتمعة تستدعي مراجعة دقيقة لوعود التسريع الأسّي.

هذا النقد ليس للامور السلبية بل هو ايجابي حيث انه يبرز النهج الهجين (كمي-كلاسيكي) كمسار منطقي وواعد، خاصة للتطبيقات المعقدة مثل تحليل البيانات الطبية. بناء على ذلك، يهدف بحث الدكتوراه المقترح لاستكشاف هذا المسار من خلال تصميم خوارزمية هجينة تستغل المزايا الكمومية بشكل استراتيجي، وتتجنب الاختناقات المعروفة. سأركز على تحقيق أداء قوي وقابل للتقييم بشكل جيد في مواجهة تحديات البيانات الطبية، ومقارنته بأفضل البدائل الكلاسيكية، بهدف سد الفجوة بين نظرية QML وتطبيقاتها العملية.



Thank You