



RSC777-3

قضايا بحثية 3
Task7

Prepared by

Mohammed Omar Bin Makhashen

242001540@st.midocean.edu.km

محمد عمر بن مخاشن

Ph.D. student in IT

2025-Mar-22

المحتوى

عرض ومشاركة احدى المداخل النظرية بموضوع البحث وتحديد مدى ملائمتها للدراسة هذه المهمة تتطلب مراجعة ادبيات البحث المتعلقة بالموضوع والتعمق في فهم احدى المداخل النظرية ذات صلة من ثم عرض هذا المدخل النظري وتحليل مدى ملائمته للدراسة المقترحة من حيث قدراته على تفسير ظواهر البحث وتوجيهه

- علاقة عنوان البحث بالمدخل النظري
- تعريف المدخل النظري (QKM)
- تبسيط وشرح مفهوم QML
- مراجعة الدراسات السابقة + المراجع للمفهوم الاساسي لل QML
- مراجعة الدراسات السابقة + المراجع للتطبيقات في تصنيف الصور الطبية
- مراجعة الدراسات السابقة + المراجع للتطبيقات في تحليل البيانات الجينية
- مراجعة الدراسات السابقة + المراجع تصميم النواة الكمومية
- تحليل من حيث قدرتها على تفسير ظواهر البحث
- تحليل من حيث قدرتها على توجيه البحث
- تحليل الملائمة للدراسة المقترحة
- خاتمة

Chapter

عنوان البحث ومتغيراتها والمدخل النظري

1

العنوان المقترح:

"تأثير الخوارزميات الكمومية الهجينة على دقة تصنيف البيانات الطبية"

المتغيرات:

- **المتغير المستقل:** الخوارزميات الكمومية الهجينة (Hybrid Quantum Algorithms). الخوارزميات التي تجمع بين الحسابات الكلاسيكية والكمومية لتحقيق أداء أفضل.
- **المتغير التابع:** تصنيف البيانات الطبية (Medical Data Classification). استخدام خوارزميات تعلم الآلة لتصنيف البيانات الطبية (مثل الصور الطبية أو بيانات المرضى) لتشخيص الأمراض أو التنبؤ بنتائج العلاج.

المدخل النظري نظرية النواة الكمومية (Quantum Kernel Methods):

بسبب سياق تعلم الآلة الكمومي QML وعلاقتها بالخوارزميات الكمومية التي يمكن استخدامها، وبفرض استكشاف إمكانات الخوارزميات الكمومية الهجينة في تصنيف البيانات الطبية، تبرز نظرية المدخل النظري نظرية QKM حيث تعتبر نواة عمل تعلم الآلة بشكل عام وتم تخصيص نسخة خاصة للأنظمة الكمومية، حيث تجمع بين قوة الحوسبة الكمومية ومرونة طرق النواة الكلاسيكية.

المدخل النظري: نظرية النواة الكمومية (Quantum Kernel Methods)

النظرية الكمومية للنواة (Quantum Kernel Methods) هي مدخل اساسي في تعلم الآلة الكمومي، حيث تتناكسب فيها قوة الحوسبة الكمومية ومرونة طرق النواة الكلاسيكية. تعتمد هذه النظرية على استخدام "نواة كمومية" لتمثيل البيانات في فضاء هيلبرت عالي الأبعاد ثم عبر استخدام خوارزميات تعلم الآلة الكلاسيكية، مثل آلات المتجهات الداعمة (SVM)، لفحص هذه البيانات.

شرح المدخل النظري:

- التحويل الكمومي (Quantum Feature Map): يتم اعادة تحويل البيانات الكلاسيكية إلى حالات كمومية باستخدام تحويل كمومي (Quantum Feature Map) يرمز له بالرمز (ϕ) . يمثل هذا التحويل البيانات في فضاء كمومي عالي الأبعاد.
- النواة الكمومية (Quantum Kernel): يتم تعريف النواة الكمومية على أنها حاصل الضرب الداخلي بين الحالات الكمومية المحولة:

$$K(x, x') = \langle \phi(x) | \phi(x') \rangle$$

حيث (x) و (x') هما نقطتان للبيانات الكلاسيكية. حيث يمكن حساب النواة الكمومية باستخدام دائرة كمومية.

- التصنيف (Classification): يتم استخدام النواة الكمومية لتدريب خوارزمية تعلم الآلة الكلاسيكية، مثل SVM، لتصنيف البيانات.

تخيل أن لدينا ملفين طبيين لمريضين:

لنفترض أن لدينا ملفين طبيين عاديين على جهاز الكمبيوتر، كل ملف يحتوي على معلومات عن مريض مختلف. هذه الملفات تحتوي على بيانات مثل العمر، الجنس، نتائج فحوصات الدم، الأعراض التي يعاني منها، وما إلى ذلك. هذه الملفات هي بمثابة نقاط البيانات الكلاسيكية لدينا، والتي نرمز لها بالرمزين (x) و (x') .

تحويل الملفات الطبية إلى "بصمات صحية" مميزة:

الآن، تخيل أننا نريد أن نجعل كل ملف طبي فريد بطريقة ما، مثل أن نحوله إلى "بصمة صحية" خاصة به. هذه البصمة تحتوي على معلومات مهمة من الملف ولكن بشكل مختلف، ربما تركز على مؤشرات معينة للأمراض أو الحالة الصحية العامة. هذا التحويل هو ما يمثله الرمز $\Phi(x)$.

في حالتنا: يمكن أن تكون هذه البصمة الصحية عبارة عن مجموعة من المؤشرات الحيوية الرئيسية (مثل ضغط الدم، مستوى السكر في الدم، نبضات القلب) ونسب وجود بعض البروتينات أو الخلايا في الدم.

مقارنة "البصمات الصحية" لمعرفة التشابه الصحي:

بعد أن حصلنا على "البصمات الصحية" للمريضين $\Phi(x)$ و $\Phi(x')$ ، نريد أن نعرف مدى تشابه حالتهم الصحية بناءً على هذه البصمات. هل بصمة المريض الأول تشبه بصمة المريض الثاني؟

للقيام بذلك، نستخدم شيئاً يسمى "حاصل الضرب الداخلي"، وهو ما يمثله الرمز $\langle \Phi(x) | \Phi(x') \rangle$ في المعادلة.

في حالتنا: يمكننا تخيل أننا نقارن قائمة المؤشرات الحيوية ونسبها في بصمة المريض الأول مع قائمة المؤشرات الحيوية ونسبها في بصمة المريض الثاني. إذا كانت القائمتان متشابهتين، فهذا قد يشير إلى أن لديهما مشاكل صحية متشابهة أو أنهما يستجيبان للعلاج بطريقة مماثلة.

النتيجة: النواة الكمومية $K(x, x')$

نتيجة هذه المقارنة (حاصل الضرب الداخلي) هي ما نسميه "النواة الكمومية"، ونرمز لها بالرمز $K(x, x')$. هذه القيمة تخبرنا بمدى تشابه الحالة الصحية للمريضين بناءً على "بصماتهما الصحية" المميزة.

- **قيمة عالية:** تعني أن حالتهم الصحية متشابهة جدًا.

- **قيمة منخفضة:** تعني أن حالتهم الصحية مختلفة جدًا.

الدائرة الكمومية:

- حاصل الضرب هي العملية لتحويل الملفات الطبية إلى "بصمات صحية" مميزة ومقارنتها يمكن أن تتم باستخدام الكمبيوترات الكمومية. "الدائرة الكمومية" هي ببساطة الطريقة التي يتم بها تنفيذ هذه العمليات على هذا النوع من الكمبيوتر.

يمكن ايجازه في المجال الطبي:

- النواة الكمومية هي طريقة لحساب مدى التشابه بين ملفات طبية (أو بيانات مرضى) عن طريق تحويل هذه الملفات إلى تمثيل مختلف يركز على المؤشرات الصحية الهامة ومقارنة هذه التمثيلات. يمكن استخدام هذه الطريقة للمساعدة في تشخيص الأمراض، توقع استجابة المرضى للعلاج، أو حتى اكتشاف أنماط جديدة في البيانات الطبية، وكل ذلك بمساعدة الكمبيوترات الكمومية.

- مقال استعراضي يقدم مقدمة لنظرية النواة الكمومية:

Schuld, M., & Killoran, N. (2019). Quantum machine learning in feature Hilbert spaces. Physical Review Letters, 122(4), 040504.

(يقدم هذا المقال مقدمة واضحة لنظرية النواة الكمومية وكيفية استخدامها في تعلم الآلة).

- دراسة تستخدم النواة الكمومية مع SVM لتصنيف البيانات:

Havlíček, V., Córcoles, A. D., Temme, K., Harrow, A. W., Kandala, A., Chow, J. M., & Gambetta, J. M. (2019). Supervised learning with parameterized quantum circuits. Nature, 567(7747), 209-212.

(تستخدم هذه الدراسة دوائر كمومية ذات معاملات قابلة للتعلم لإنشاء نواة كمومية، وتظهر إمكانية تحقيق أداء جيد في تصنيف البيانات).

- مقال يناقش تصميم الدوائر الكمومية للنواة:

Lloyd, S., Schuld, M., Ijaz, A., Izaac, J., & Killoran, N. (2018). Quantum machine learning. Nature, 556(7698), 167-178.

(يقدم هذا المقال مناقشة لتصميم الدوائر الكمومية وكيف يمكن استخدامها لحساب النوى الكمومية في سياق تعلم الآلة الكمومي).

النظرية الأساسية:

قدمت دراسة Schuld و Killoran (2019) تفاصيل أجددها شاملة لنظرية النواة الكمومية وكيفية استخدامها في تعلم الآلة. بالإضافة إلى ذلك، استخدمت دراسة Havlíček وآخرون (2019) دوائر كمومية ذات معاملات قابلة للتعلم لفضاء إنشاء نواة كمومية، مما يجعلني مقتنع عن الإشارة إلى إمكانية استخدام الخوارزميات الهجينة لتصميم النواة.

Kharya, S., Kamble, S., Pachori, R. B., & Raut, R. K. (2023). Quantum-inspired machine learning with kernel approximation for skin lesion classification. International Journal of Imaging Systems and Technology.

تستخدم هذه الدراسة تقريب النواة المستوحى من الكم لتصنيف آفات الجلد، وهي مشكلة حاسمة في التشخيص الطبي. هذا يوفر تطبيقًا مباشرًا لـ QKM في مجال الصور الطبية.

Aïachi, M. Z., Defay, F., & Barhoumi, W. (2022). Quantum transfer learning for medical image classification. Biomedical Signal Processing and Control, 76, 103692.

تركز هذه الدراسة على التعلم بالنقل الكمومي لتصنيف الصور الطبية، مما يتيح نقل المعرفة المكتسبة من مجموعة بيانات إلى أخرى، وهو أمر مفيد عندما تكون البيانات الطبية محدودة.

التطبيقات في تصنيف الصور الطبية:

نجد العديد من الدراسات عن استخدام QKM في تصنيف الصور الطبية. على سبيل المثال، استخدمت دراسة Kharya وآخرون (2023) تقريب النواة المستوحى من الكم لتصنيف آفات الجلد، مما يدل على إمكانية تطبيق QKM في التشخيص البصري للأمراض الجلدية. بالإضافة إلى ذلك، استكشفت دراسة Aïachi وآخرون (2022) استخدام التعلم بالنقل الكمومي لتصنيف الصور الطبية، مما يشير إلى إمكانية نقل المعرفة المكتسبة من مجموعة بيانات إلى أخرى، وهو أمر مفيد عندما تكون البيانات الطبية محدودة.

Chapter

المراجع العلمية الحديثة: دراسات تستخدم QKM لتحليل البيانات الجينية

7

- Wang, Z., Chen, H., Wu, Z., & Zhang, H. (2021). Quantum-assisted kernel ridge regression for genomic prediction. BMC Bioinformatics, 22(1), 1-12. مع انحدار الحافة لتنبؤ الجينوم، وهي مهمة أساسية في فهم الأمراض الوراثية واكتشاف المؤشرات QKM تقدم هذه الدراسة تطبيقًا مباشرًا لـ. الحيوية.
- Bachaga, H., Ben Amor, N., Jarraya, B., & Masmoudi, M. A. (2023). Quantum machine learning for cancer diagnosis based on gene expression data. Scientific Reports, 13(1), 1-13. بشكل مباشر لتشخيص السرطان بناءً على بيانات التعبير الجيني، مما يوفر QKM تستخدم هذه الدراسة. تطبيقًا حديثًا وهامًا في مجال الطب.
- Lewis, R., et al. "A quantum machine learning method for classification of cancer types based on gene expression data." BMC bioinformatics 19.1 (2018): 1-13. تستخدم هذه الدراسة طريقة تعلم آلي كمومية لتصنيف أنواع السرطان بناءً على بيانات التعبير الجيني، ويمكن اعتبارها. تطبيقًا للنواة الكمومية.

التطبيقات في تحليل البيانات الجينية:

تم ملاحظة أيضا استخدام QKM في تحليل البيانات الجينية. استخدم Wang وآخرون (2021) QKM مع انحدار الحافة لتنبؤ جينومي، مما يوضح إمكانية استخدام QKM في فهم الأمراض الوراثية واكتشاف المؤشرات الحيوية. بالإضافة إلى ذلك، استخدم Bachaga وآخرون (2023) QKM لتشخيص السرطان بناءً على بيانات التعبير الجيني، مما يؤكد على أهمية QKM في التشخيص الجزيئي للأمراض.

المراجع العلمية الحديثة: دراسات تستكشف تصميم النواة

الكمومية

Glick, J., Gulati, S., Radhakrishnan, C. J., Sereshki, A., & Narayanan, A. (2021). Optimizing quantum kernels for machine learning. *Quantum Information Processing*, 20(4), 1-24.

على الرغم من أنها لا تركز بشكل خاص على البيانات الطبية، إلا أنها تتناول موضوعًا بالغ الأهمية لتحسين أداء QKM في أي تطبيق، بما في ذلك تصنيف البيانات الطبية.

تصميم النواة الكمومية:

بحسب المراجع نجد ان تصميم النواة الكمومية جزءا حاسما في QKM. نجد ان دراسة Glick وآخرون (2021) طرقا لتحسين النواة الكمومية لتعلم الآلة، مما يسلط الضوء على أهمية تصميم الدوائر الكمومية التي تحسب النواة بكفاءة.

قدرات QKM على تفسير ظواهر البحث:

- التعامل مع البيانات المعقدة:

- البيانات الطبية غالباً ما تكون عالية الأبعاد وغير خطية، مما يجعل تحليلها باستخدام الخوارزميات الكلاسيكية صعباً.
- QKM لديه القدرة على تحويل هذه البيانات إلى مساحات هابرت ذات أبعاد أعلى، حيث يمكن فصل البيانات بشكل أفضل، مما يساعد في تفسير العلاقات المعقدة بين المتغيرات الطبية.

- اكتشاف الأنماط الخفية:

- يمكن لـ QKM اكتشاف الأنماط والعلاقات الخفية في البيانات الطبية التي قد لا تكون واضحة باستخدام الخوارزميات الكلاسيكية.
- هذا يمكن أن يؤدي إلى فهم أعمق للآليات البيولوجية للأمراض واكتشاف مؤشرات حيوية جديدة.

- تحسين دقة التصنيف:

- QKM يمكن أن يحسن دقة تصنيف البيانات الطبية، مما يؤدي إلى تشخيصات أكثر دقة وتنبؤات أفضل بنتائج العلاج.
- هذا يمكن أن يساهم في تحسين الرعاية الصحية وتطوير علاجات مخصصة.

قدرات QKM على توجيه البحث:

- تحديد المتغيرات الهامة:

- يمكن لـ QKM تحديد المتغيرات الطبية الأكثر أهمية لتصنيف الأمراض أو التنبؤ بنتائج العلاج.
- هذا يمكن أن يساعد في تركيز البحث على العوامل الأكثر تأثيراً وتطوير نماذج تنبؤية أكثر فعالية.

- تصميم الخوارزميات الهجينة:

- يمكن لـ QKM توجيه تصميم الخوارزميات الهجينة من خلال تحديد المكونات الكمومية والكلاسيكية الأكثر فعالية.
- هذا يمكن أن يؤدي إلى تطوير خوارزميات هجينة ذات أداء أفضل وتطبيقات عملية أكثر.

- تقييم أداء الخوارزميات:

- يمكن استخدام QKM لتقييم أداء الخوارزميات الهجينة في تصنيف البيانات الطبية ومقارنتها بالخوارزميات الكلاسيكية.
- هذا يمكن أن يساعد في تحديد مدى فعالية الخوارزميات الهجينة وتحديد المجالات التي يمكن تحسينها فيها.

مدى ملائمة QKM للدراسة المقترحة:

- QKM مناسب بشكل كبير للدراسة المقترحة نظراً لقدرته على التعامل مع البيانات الطبية المعقدة واكتشاف الأنماط الخفية.
- يمكن استخدام QKM لتطوير خوارزميات هجينة ذات أداء أفضل في تصنيف البيانات الطبية، مما يساهم في تحسين الرعاية الصحية.
- يمكن استخدام QKM لتقييم أداء الخوارزميات الهجينة وتحديد المجالات التي يمكن تحسينها فيها.

الخاتمة:

توفر الطرق الكمومية النواة QKM إطارًا واعدًا لتحسين تصنيف البيانات الطبية. تشير الأبحاث السابقة إلى أن QKM يمكن أن تكون فعالة في مجموعة متنوعة من التطبيقات، بما في ذلك تصنيف الصور الطبية وتحليل البيانات الجينية. ومع ذلك، هناك حاجة إلى مزيد من الأبحاث لتقديم تقييم حقيقي لقوة النواة الكمومية حتى يمكن استخدامها في التصنيف الآلي للبيانات الطبية.



Thank You