



RSC811-3

مهارات بحثية 3

Task3

Prepared by

Mohammed Omar Bin Makhashen

242001540@st.midocean.edu.km

محمد عمر بن مخاشن

Ph.D. student in IT

2025-Feb-22

المحتوى

تقييم مشكلة بحثية لرسالة دكتوراه

- توضيح اسلوب الصياغة ونجاح في عرضها (من صفحة 3 الى صفحة 7)
- كتابة مشكلة بحثية لمتغيرات (من صفحة 8 الى صفحة 12)

عنوان الرسالة: (Exploratory Quantum Machine Learning Techniques For Hybrid Systems)

اسم المؤلف: (Dominic Pasquali)

الجامعة: (UC Santa Cruz)

الدرجة العلمية: دكتوراه في الفلسفة (Doctor of Philosophy)

تاريخ تقديم الرسالة: ٢٠٢٣ ديسمبر

المشكلة البحثية وتقييمها

2

تقييم المشكلة البحثية:

- **الأهمية:** المشكلة البحثية مهمة وذات صلة بالمجال. يهدف البحث إلى استكشاف طرق لدمج التعلم الآلي الكمومي (Quantum Machine Learning - QML) مع نماذج التعلم الآلي الأخرى (الكلاسيكية والشبكات العصبية المتصاعدة). هذا له أهمية كبيرة لأن:
 - التعلم الآلي الكمومي هو مجال ناشئ لديه القدرة على حل المشكلات التي يصعب حلها باستخدام الطرق الكلاسيكية.
 - الشبكات العصبية المتصاعدة (Spiking Neural Networks - SNNs) هي نماذج قوية وفعالة من الناحية الحسابية تحاكي طريقة عمل الدماغ البيولوجي.
 - دمج QML مع نماذج أخرى يمكن أن يؤدي إلى إنشاء نماذج أكثر قوة وكفاءة.
- **الجدة والابتكار:** يساهم البحث في المعرفة من خلال اقتراح واستكشاف تقنيات جديدة لدمج QML مع نماذج أخرى. على سبيل المثال:
 - استخدام الاهتمام الذاتي الكمي في نماذج Transformer.
 - استخدام المصفوفات أحادية الوحدة للدوائر الكمومية.
 - دمج QML مع الشبكات العصبية المتصاعدة.
- **الوضوح والتركيز:** المشكلة البحثية محددة بوضوح وتركز على استكشاف تقنيات محددة لدمج QML مع نماذج أخرى. هذا يساعد على توجيه البحث وتسهيل تقييم النتائج.

أسلوب الصياغة:

- **مقدمة واضحة:** يقدم الباحث المشكلة البحثية بوضوح في مقدمة الرسالة. يوضح أهمية QML، والشبكات العصبية المتصاعدة، ودمج هذه التقنيات معًا.
- **خلفية كافية:** يقدم الباحث خلفية كافية عن المفاهيم الأساسية في التعلم الآلي، QML، والشبكات العصبية المتصاعدة. هذا يساعد القارئ على فهم المشكلة البحثية وأهميتها.
- **تحديد الفجوات:** يحدد الباحث الفجوات الموجودة في الأدبيات ويشرح كيف يهدف هذا البحث إلى معالجة هذه الفجوات.
- **توضيح الأهداف:** يوضح الباحث أهداف البحث بوضوح، مثل تصميم واستكشاف تقنيات جديدة لدمج QML مع نماذج أخرى، وتقييم أداء هذه التقنيات.

مدى النجاح في عرض المشكلة:

- **نجاح كبير:** يعرض الباحث المشكلة البحثية بنجاح كبير. يتم تقديم المشكلة بوضوح، مع توفير خلفية كافية وتحديد الفجوات في الأدبيات وتوضيح الأهداف. هذا يساعد القارئ على فهم أهمية البحث والمساهمة التي يقدمها.
- **تحسين محتمل:** في الدراسات المستقبلية، يمكن للباحث تقديم المزيد من التفاصيل حول التحديات المحددة التي تواجه دمج QML مع نماذج أخرى، وشرح كيف يمكن للتقنيات المقترحة معالجة هذه التحديات.

المشكلة البحثية المقترحة:

4

المشكلة البحثية المقترحة:

- "تحسين كفاءة استخلاص الميزات (Feature Extraction) باستخدام خوارزمية كمومية هجينة لتعزيز أداء التعرف على الصور."

الخلفية:

- التعرف على الصور هو مهمة أساسية في مجال رؤية الحاسوب. غالبًا ما تتطلب هذه المهمة استخلاص الميزات المناسبة من الصور قبل إدخالها إلى نموذج التعلم الآلي. خوارزميات استخلاص الميزات التقليدية قد تكون مكلفة من الناحية الحسابية. يمكن أن توفر خوارزميات التعلم الآلي الكمومية الهجينة طريقة بديلة لتحسين كفاءة استخلاص الميزات.

الهدف:

- يهدف هذا البحث إلى استكشاف كيف يمكن لخوارزمية كمومية هجينة جديدة لاستخلاص الميزات أن تحسن كفاءة استخلاص الميزات وأداء التعرف على الصور.
-

المشكلة البحثية المقترحة:

5

الفرضيات:

- الفرضية الرئيسية: استخدام الخوارزمية الكمومية الهجينة المقترحة لاستخلاص الميزات سيؤدي إلى زيادة كفاءة استخلاص الميزات (بتقليل الوقت أو الموارد الحسابية المطلوبة) وتحسين دقة التعرف على الصور مقارنة بالطرق الكلاسيكية.

فرضيات فرعية:

ستكون هناك علاقة إيجابية بين كفاءة استخلاص الميزات ودقة التعرف على الصور.
ستؤثر بنية الخوارزمية الكمومية الهجينة المستخدمة بشكل كبير على كفاءة استخلاص الميزات ودقة التعرف على الصور.

المتغيرات:

المتغيرات المستقلة:

- طريقة استخلاص الميزات: (أ) الخوارزمية الكمومية الهجينة المقترحة، (ب) خوارزمية كلاسيكية (مثل SIFT أو HOG).
- هيكل الخوارزمية الكمومية الهجينة: (عدد الكيوبتات، نوع الدوائر الكمومية المستخدمة، وما إلى ذلك).

المتغيرات التابعة:

- دقة التعرف على الصور: (تقاس بالنسبة المئوية للصور المصنفة بشكل صحيح).
- كفاءة استخلاص الميزات: (تقاس بالوقت أو الموارد الحسابية المطلوبة لاستخلاص الميزات).

المتغيرات الوسيطة:

جودة الميزات المستخرجة: (تقاس بمعايير مثل التمييزية، الصلابة، وقابلية التعميم). هذه الجودة تؤثر على الأداء النهائي للتعرف على الصور.

- المنهجية:

تصميم الخوارزمية الكمومية الهجينة: قم بتصميم خوارزمية QML هجينة لاستخلاص الميزات. يمكن أن يعتمد هذا التصميم على تقنيات QML الموجودة أو يتضمن عناصر جديدة مبتكرة.

تنفيذ الخوارزميات: القيام بتنفيذ كل من الخوارزمية الكمومية الهجينة وخوارزمية كلاسيكية.

- تحديد مجموعة بيانات: استخدم مجموعة بيانات صور قياسية (مثل CIFAR-10 أو ImageNet) لتقييم أداء الخوارزميات.

- استخلاص الميزات: باستخلاص الميزات من الصور باستخدام كلتا الخوارزميتين.

- تدريب النموذج: بتدريب نموذج تعلم آلي (مثل شبكة عصبونية تلافيفية) باستخدام الميزات المستخرجة من كلتا الخوارزميتين.

- تقييم الأداء: بتقييم دقة التعرف على الصور وكفاءة استخلاص الميزات لكلا النهجين.

- تحليل النتائج: مقارنة النتائج بين النهجين، وحل كيف تؤثر المتغيرات المستقلة والوسيطة على المتغيرات التابعة.

- أهمية البحث:

- يمكن أن يؤدي هذا البحث إلى تطوير خوارزميات استخلاص ميزات أكثر كفاءة وقوة، مما يساهم في تحسين أداء تطبيقات التعرف على الصور في مجموعة متنوعة من المجالات.



Thank You