

Quantum AI – Quantum-inspirierte Stimmerkennung

Alexander Diefenbacher, Robin Misia, Javier Villalba-Diez

Zusammenfassung: In der vorliegenden Studie wird eine innovative Untersuchung der Stimmerkennung vorgestellt, bei der herkömmliche Convolutional Neural Networks mit neuartigen Quantencomputing-Ansätzen verglichen werden. Die Problemstellung konzentriert sich auf die Herausforderungen der akustischen Signalverarbeitung, insbesondere der Stimmerkennung, die durch Umgebungsgeräusche und Klangverzerrungen beeinträchtigt wird. Die zentrale Fragestellung untersucht, inwieweit Quanten-Algorithmen im Vergleich zu Convolutional Neural Networks in der Lage sind, Genauigkeit und Effizienz der Stimmerkennung unter variablen Bedingungen zu verbessern. Ziel der Studie ist es, die Leistungsfähigkeit von Quantenalgorithmen in Bezug auf Geschwindigkeit, Genauigkeit und die Fähigkeit zur Verarbeitung großer Datensätze zu evaluieren. Durch systematische Experimente und Analysen wird eine vergleichende Bewertung zwischen den beiden Technologien angestrebt, um festzustellen, welche Methode für zukünftige Anwendungen in der Stimmerkennung besser geeignet ist.

Schlüsselwörter: Quantum AI, Convolutional Neural Networks, Stimmerkennung, Quantentechnologie, Akustische Signalverarbeitung

1 Einleitung

Quantencomputing ist ein Forschungsgebiet mit der Möglichkeit einen neuen Standard in der Verarbeitung von Daten zu schaffen (Kharsa et al., 2023). In dieser Studie liegt der Fokus auf Quantencomputing-Ansätzen, auch Quantencomputing-Algorithmen, im Bereich der Stimmerkennung (Sanders, 2023). Quantencomputing-Algorithmen beschreiben Methoden, bei welchen die Quantencomputertechnologie verwendet wird, um Daten zu verarbeiten (Rietsche et al., 2022). Solche Quantencomputing-Algorithmen sollen verwendet werden um Stimmerkennungstechnologien, also Technologien zur Erkennung menschlicher Stimmen, zu verbessern (Sachdeva et al., 2023). Für eine Stimmerkennung ist ein Convolutional Neural Network (CNN) der State-of-the-Art. Ein CNN ist ein künstliches neuronales Netz mit verschiedenen Schichten im Bereich des maschinellen Lernens (Kharsa et al., 2023). Bei einer schlechten Audioqualität als Basis der Stimmerkennung, also einer niedrigen Qualität der Tonaufnahme oder den Umständen während der Aufnahme, welche die Aufnahmequalität negativ beeinflussen, sinkt die Genauigkeit eines klassischen CNN (Sanders, 2023). Um diese sinkende Genauigkeit zu verringern und die Effizienz der Stimmerkennung zu steigern, wird diese Studie den Einsatz von Quantencomputing-Algorithmen als mögliche Verbesserung untersuchen (Hema und Arowolo, 2023). Die Problemstellung leitet sich aus den Grenzen der aktuellen Verfahren in der Stimmerkennung ab, welche besonders bei schlechten Aufnahmebedingungen an ihre Leistungsgrenzen stoßen. Konventionelle CNN-Algorithmen, die in der Stimmerkennung weit verbreitet sind, zeigen Schwächen bei der Verarbeitung von Signalen mit hohem Rauschanteil oder bei der Unterscheidung zwischen ähnlich klingenden Stimmen (Cantiabala et al. 2022). Dies führt zu einer geringeren Erkennungsgenauigkeit und Effizienz, was insbesondere für Anwendungen wie die Sprachassistenten oder in der Sicherheitstechnik problematisch ist (Ahmed, 2021). Die Notwendigkeit, diese Grenzen zu überwinden, motiviert die Erforschung von Quantencomputing-Algorithmen als mögliche Alternative.

Die zentrale Forschungsfrage der Studie lautet: „Können mit dem Einsatz von Quantenlayern bearbeitete Spektrogramme, in den Aspekten Geschwindigkeit und Genauigkeit bei der Stimmerkennung, effizienter sein als klassische CNN-Modelle?“ Diese Frage zielt darauf ab, das Potenzial von Quantenalgorithmen für die Verbesserung der Stimmerkennung zu erkunden. Das Ziel dieser Forschungsarbeit ist zuerst die Erstellung eines CNNs für die Stimmerkennung, um Ergebnisse für einen Vergleich zu erhalten. Danach werden Quantum Convolutional Neural Networks (QCNNs) mit verschiedenen Quantenlayern trainiert, um unterschiedliche

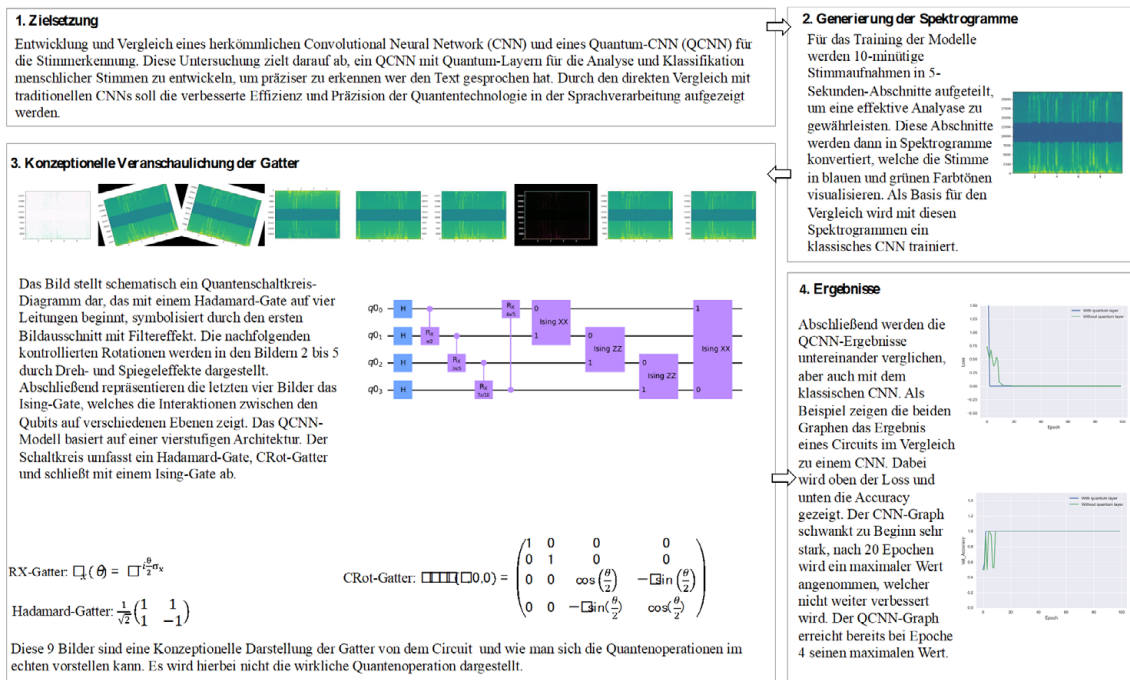
Ergebnisse zu erhalten, welche anschließend mit dem Ergebnis des klassischen CNNs verglichen werden. Durch den Vergleich der Endergebnisse wird festgehalten welches Model die beste Performance anbietet.

Bildungscampus



HOCHSCHULE HEILBRONN

Quantum-Inspirierte Filterung für verbesserte Stimmerkennung mit Deep Learning



Quantum-Inspirierte Filterung für verbesserte Stimmerkennung | Diefenbacher, Misia, Villalba-Diez / Wirtschaft / MDT | WiSe 2023/24

Abbildung 1: Graphical Abstract (eigene Darstellung)

In Abbildung 1 ist das Graphical Abstract der Forschungsarbeit zu sehen. Dabei ist es in vier Abschnitte unterteilt. Der erste Abschnitt beginnt mit der Zielsetzung hier wird das Ziel der Forschungsarbeit beschrieben. Im darauffolgenden Abschnitt werden die Vorbereitungen und das Training eines klassischen CNNs für die Vergleichsgrundlage gebildet. Der dritte Abschnitt umfasst die Verarbeitung der Spektrogramme durch die Quantenlayer und die QCNN trainierten Modelle. Abschließend werden die Ergebnisse dokumentiert und mit denen des klassischen CNNs verglichen.

2 Theoretische Grundlagen

In diesem Kapitel werden die verschiedenen Quantenfilter vorgestellt, die im Rahmen der Forschungsarbeit verwendet werden. Bevor im Weiteren auf diese Quantenfilter eingegangen wird, ist es wichtig, einige Begriffe aus dem Bereich des Deep Learning und Quantencomputing zu erklären. Diese Begriffe sind nicht nur für das Verständnis der Filter wichtig, sondern auch zur Schaffung einer soliden Basis für die gesamte Forschungsarbeit. CNNs stellen ein zentrales Modell im maschinellen Lernen dar, das speziell für die effiziente Verarbeitung und Analyse von Bildern entwickelt wurde. Sie unterscheiden sich von traditionellen neuronalen Netzwerken durch ihre Fähigkeit, lokale Faltungen auf kleine Bereiche des Eingabebilds anzuwenden (Henderson et al., 2020). Diese Methode, bei der ein Kern wiederholt auf verschiedene Bildbereiche angewendet wird, resultiert in einer Sammlung von Ausgabepixeln, die unterschiedliche Merkmale des Eingabebildes darstellen (Belyaev et al., 2018).

Diese Netzwerke nutzen das Prinzip der Faltungsschicht, wobei sie sich von traditionellen neuronalen Netzwerken durch die Anwendung lokaler Faltungen auf kleine Bereiche des Eingabebildes unterscheiden (Krizhevsky et al., 2017). Diese Methode, bei der derselbe Kernel auf verschiedene Regionen des Bildes angewendet wird, resultiert in einer Reihe von Ausgabepixeln, die jeweils verschiedene Merkmale des Eingabebildes repräsentieren und ein neues, bildähnliches Objekt formen (Belyaev et al., 2018).

Die Struktur von CNNs umfasst des weiteren Pooling-Schichten und vollständig verbundene Schichten, die gemeinsam an der Erstellung einer räumlichen Hierarchie von Merkmalen arbeiten (Yamashita et al., 2018). Diese Fähigkeit der CNNs, automatisch Merkmale aus Bildern zu extrahieren und zu lernen, macht sie zu einem wertvollen Instrument in der Bildverarbeitung. Die Forschungsarbeiten von O'Shea betonen die Effizienz von CNNs in der automatischen Merkmalsextraktion und ihrer weiteren Verarbeitung, was sie zu einem Schlüsselement in der modernen Technologie des maschinellen Lernens macht (O'Shea, 2015).

Insgesamt bieten CNNs eine einzigartige Kombination aus lokaler Faltungsverarbeitung und Lernen räumlicher Merkmals-hierarchien, was sie für Anwendungen in der Bildverarbeitung und darüber hinaus besonders geeignet macht. Ihre Fähigkeit, komplexe Muster und Strukturen in visuellen Daten zu erkennen und zu interpretieren, hat sie zu einem unverzichtbaren Werkzeug in vielen Bereichen der künstlichen Intelligenz gemacht (Yamashita et al. 2018).

Deep Learning, eine moderne Form des maschinellen Lernens, hat signifikante Fortschritte in der künstlichen Intelligenz (KI), insbesondere in der Bildverarbeitung und Mustererkennung, ermöglicht (Goularas und Kamis, 2019). Diese Technik erlaubt es Maschinen, komplizierte Muster in Daten zu erkennen und zu interpretieren, indem sie mehrere Ebenen der Datenabstraktion durchlaufen. Diese Fähigkeit, komplexe Datenstrukturen zu verarbeiten, hat Deep Learning zu einem unverzichtbaren Werkzeug in vielen KI-Anwendungen gemacht (Tripathy und Singh, 2023).

Ein Kernaspekt des Deep Learning ist das Training von Modellen, das auf der Verarbeitung und Analyse großer Datensätze basiert. Dieser Prozess kann jedoch zeitaufwändig sein und erfordert oft umfangreiche Datensätze (Li et al., 2020). Hier bietet das Quantencomputing ein enormes Potenzial. Mit seiner Fähigkeit, Berechnungen viel schneller als herkömmliche Computer durchzuführen, könnte Quantencomputing die Effizienz des Lernprozesses erheblich steigern (Kerenidis et al., 2019). Darüber hinaus könnte die Quantentechnologie helfen, den Bedarf an großen Datensätzen zu reduzieren, indem sie effizientere Algorithmen für das maschinelle Lernen ermöglicht (Viamontes et al., 2003).

Die Kombination von Deep Learning mit Quantencomputing könnte somit eine neue Ära in der KI einläuten, in der schnelleres und effizienteres Lernen möglich ist. Diese Fortschritte könnten in zahlreichen Bereichen, von der medizinischen Bildanalyse bis hin zu fortgeschrittenen Robotik Systemen, transformative Auswirkungen haben. Insgesamt zeigt sich, dass Deep Learning in Verbindung mit Quantentechnologien das Potenzial hat, die Grenzen der aktuellen KI-Forschung und -Anwendung zu erweitern und neue, innovative Lösungsansätze zu ermöglichen (Pan et al., 2023).

Nachdem dieser Teil der theoretischen Grundlagen vermittelt wurden, wird im Folgenden auf die verwendeten Quanten-Gatter eingegangen. Diese umfassen das Hadamard Gate, das RX-Rotaionsgate, das Controlled Rotation Gate und das Ising Gate. Das Hadamard Gate ist ein Einzel-Qubit-Gatter, welches in Quantenalgorithmen verwendet wird, um ein Qubit von einem klaren Zustand in eine sogenannte Superposition der Basiszustände $|0\rangle$ und $|1\rangle$ zu versetzen. Diese Superposition ermöglicht es dem Qubit, Werte zwischen den beiden Zuständen anzunehmen, bis es gemessen wird. Die mathematische Darstellung des Hadamard Gates erfolgt durch die sogenannte Hadamard Matrix:

$$\frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$$

Die Matrix wird auf den Zustand des Qubits angewandt und ermöglicht die gewünschte Superposition der Basiszustände. Das Hadamard Gate ist ein Schlüsselement in der Umsetzung von Quantenalgorithmen (Nielsen und Chuang, 2010).

Das RX-Rotationsgate ermöglicht die präzise Steuerung und Veränderung des Zustandes eines Qubits, indem eine Rotation um die X-Achse an der sogenannten Bloch-Kugel durchgeführt wird. Die Bloch-Kugel ist eine geometrische Darstellung aller möglichen Zustände eines Qubits. Die mathematische Darstellung des RX-Rotationsgatters lautet:

$$R_x(\theta) = \begin{pmatrix} \cos\left(\frac{\theta}{2}\right) & -i \sin\left(\frac{\theta}{2}\right) \\ -i \sin\left(\frac{\theta}{2}\right) & \cos\left(\frac{\theta}{2}\right) \end{pmatrix}$$

Dabei steht θ für den Rotationswinkel um die X-Achse der Bloch-Kugel. RX-Gate steht für eine präzisen Kontrolle der Qubit-Zustände. Durch den Rotationswinkel kann gezielt eingestellt werden, wie zwischen den Basiszuständen eines Qubits, also $|0\rangle$ und $|1\rangle$ oder den Superpositionen gewechselt wird. Das ist erforderlich für Quantenalgorithmen, bei denen eine präzise Manipulation der Qubit-Zustände erforderlich ist (Nielsen und Chuang, 2010).

Das Controlled Rotation Gate führt eine Rotation auf einem Qubit durchführt. Die Rotation hängt jedoch vom Zustand eines anderen Qubits ab. Dadurch werden bedingte Operationen im Quantencomputing ermöglicht, bei welchen die Rotation auf einem Qubit von einem anderen Qubit kontrolliert wird (Nielsen und Chuang, 2010).

Das Ising Gate ist ein spezielles Gatter, welches Wechselwirkungen im Ising-Modell simuliert. Das Ising-Modell ist ein Konzept in der statistischen Mechanik und wird oft zur Quantensimulation verwendet (Nielsen und Chuang, 2010).

3 Materialien und Methoden

In dieser Forschungsarbeit erfolgt ein Vergleich zwischen CNN und QCNN-Modellen im Bereich der Stimmerkennung. Um einen validen und aussagekräftigen Vergleich sicherzustellen, fokussiert sich die Forschungsarbeit auf zwei Hauptkriterien die ‚Accuracy‘ und ‚Loss‘ Funktion. Diese Metriken sind entscheidend um die Modelle zu bewerten und zu vergleichen. Die in der Studie verwendeten Quantenfilter, die im QCNN-Modell verwendet werden, werden detailliert in Kapitel zwei erklärt. Es ist anzumerken, dass der Datensatz der Studie auf Aufnahmen von nur zwei Personen basiert. Dies stellt eine gewisse Einschränkung in Bezug auf die Datenvarianz dar, ist jedoch aufgrund der begrenzten Verfügbarkeit von Daten unvermeidbar. Trotz dieser Einschränkung bieten die Ergebnisse wertvolle Einblicke in die Leistungsfähigkeit der Modelle unter den gegebenen Bedingungen.

Um die Modelle zu optimieren, wurden sie mehrfach in verschiedenen Varianten trainiert. Nach jedem Training wurden die Ergebnisse sorgfältig analysiert, um kontinuierliche Verbesserungen zu gewährleisten. Diese iterative Vorgehensweise ermöglichte eine feinabgestimmte Anpassung der Modelle, um optimale Ergebnisse zu erzielen. Sowohl die CNN- als auch die QCNN-Modelle wurden unter Verwendung der unveränderten Spektrogramme trainiert. Für das QCNN-Modell wurden zusätzlich die spezifischen Quantenfilter angewandt.

Diese bearbeiteten Spektrogramme dienen dann als Grundlage für das Training und die Validierung des QCNN-Modells. Die gewonnenen Erkenntnisse liefern wichtige Impulse für zukünftige Forschungsarbeiten in diesem Bereich, insbesondere hinsichtlich der Anpassung und Optimierung von Quantenfiltern und der Ausweitung des Datensatzes für eine umfassendere Analyse.

Für die Durchführung des Projektes wurde der Code von Villalba-Diez verwendet und auf die Bedürfnisse dieser Zielsetzung angepasst (Villalba-Diez, 2021). Dabei dienen die Quantengatter aus dieser Forschungsstudie als Grundlage für die Quantenlayer in dieser Forschungsarbeit. Die ursprüngliche Implementierung der Quantengatter ist auf die Verarbeitung von Bildern ausgerichtet. In dieser Forschungsarbeit wird allerdings die Stimmerkennung mittels Audiodateien behandelt. Die Lösung dieser Herausforderung besteht darin, dass die Audiodateien in Spektrogramme, also Bilddateien, umgewandelt werden. Dazu wird die zehnminütige Audiodatei in fünf Sekunden Schnipsel unterteilt, welche dann jeweils ein Spektrogramm bilden. Für ein tiefergehendes Verständnis der implementierten Algorithmen und der erzielten Ergebnisse empfehlen wir den Besuch des dazugehörigen GitHub Repositories (Diefenbacher und Misia, 2024).

4 Ergebnisse

Dieses Kapitel stellt eine detaillierte Analyse der Ergebnisse dar. Dabei werden die zwei verschiedenen QCNNs mit dem klassischen CNN verglichen. Zuerst werden die Strukturen der zwei Circuits gezeigt, wobei der Fokus auf dem QCNN mit Hadamard liegt. Danach werden diese beiden Circuits mit den Ergebnissen des CNN verglichen. Anschließend wird eine Bewertung der Accuracy, Loss und Verarbeitungsgeschwindigkeit durchgeführt.

In den Abbildungen 2 und 3 werden die beiden verwendeten Varianten der QCNN-Modelle dargestellt. Abbildung 2 ist dabei das QCNN welches das Hadamard Gate verwendet. In der anderen Variante wird auf das Hadamard Gate verzichtet. Deshalb wird das QCNN ohne Hadamard im Folgenden nur als QCNN referenziert.




Abbildung 2: QCNN mit Hadamard (eigene Darstellung)




Abbildung 3: QCNN ohne Hadamard (eigene Darstellung)

Im direkten Vergleich dazu erreichen die QCNN-Modelle eine hohe Accuracy in einer wesentlich kürzeren Zeitspanne. Dies wird in Abbildung 4 deutlich bei der man die drei Modelle im direkten Vergleich sehen kann. Besonders hervorzuheben ist das QCNN mit Hadamard-Transformation am Anfang, dass bereits nach den ersten Epochen eine nahezu perfekte Accuracy von 100 % erzielt. Diese schnelle Annäherung wird auch im Loss-Wert widerspiegelt, der von 19,0954 in der ersten Epoche rapide auf nahezu null fällt und über den weiteren Trainingsverlauf auf diesem Niveau verbleibt. Diese Ergebnisse unterstreichen die Effizienz und Lerngeschwindigkeit, die durch die Integration der Hadamard-Transformation erreicht wurde.




Abbildung 4: Accuracy-Vergleich (eigene Darstellung)

Die Ergebnisse der Leistungsvergleiche zwischen dem CNN-Modell und den zwei Varianten des QCNN bieten Einblicke in die Effizienz und Effektivität dieser Modelle. Das CNN-Modell zeigt eine Verbesserung in der Accuracy, die auf 100 % steigt, jedoch erst nach einer langen Trainingsphase von etwa 20 Epochen. Der Loss-Wert dieses Modells, wie man in Abbildung 5 sehen kann, verringert sich dabei stetig von anfänglich 1,2924 auf 0.0045 nach 20 Epochen, was auf eine kontinuierliche Lern- und Anpassungsfähigkeit hinweist. Diese Daten veranschaulichen eine effektive, aber zeitlich aufwendige Optimierung durch das CNN.




Abbildung 5: Loss mit Fokus auf 0-3 (eigene Darstellung)

Bei der Betrachtung von Abbildung 6 wird ein deutlicher Unterschied der Laufzeiten pro Epochen bei CNN und dem QCNN mit Hadamard sichtbar. Das klassische CNN benötigt ungefähr zwei Sekunden pro Epoche, das QCNN mit Hadamard hingegen durchschnittlich über 100 Sekunden pro Epoche. Das QCNN mit Hadamard benötigt also das 50-fache an Zeit für das Training. Dabei ist zu beachten, dass dies die Trainingsdauer des Modells abbildet und nicht die Zeit der Datenverarbeitung.




Abbildung 6: Time per Step per Epoch (eigene Darstellung)

5 Diskussion und Ausblick

Die Ergebnisse dieser Forschungsarbeit bieten aufschlussreiche Erkenntnisse über den Vergleich zwischen CNNs und QCNNs in der Stimmerkennung. Trotz der Einschränkungen durch einen begrenzten Datensatz, der nur Aufnahmen von zwei Personen umfasst, haben die Modelle signifikante Unterschiede in Bezug auf Accuracy und Loss in den ersten Epochen des Trainings gezeigt. Es wird deutlich, dass QCNNs, unterstützt durch die Anwendung spezifischer Quantenfilter, eine verbesserte Leistung im Vergleich zu traditionellen CNNs aufweisen können. Das durchgeführte Projekt stellt lediglich eine Simulation der Quantenalgorithmen in der Spracherkennung dar und wurde nicht auf einem Quantencomputer durchgeführt (Thejha et al., 2023). Dabei weisen die Genauigkeitswerte des QCNNs deutliche Verbesserungen auf. Hingegen ist die Dauer einer Epoche 50-fach höher als die eines herkömmlichen CNNs. Dieses Ergebnis resultiert daraus, dass die Algorithmen mit den Quantenlayern lediglich simuliert und nicht auf einem Quantencomputer ausgeführt werden. Die simulierten Quantenalgorithmen weisen demnach eine gesteigerte Genauigkeit auf, allerdings entsprechende Verbesserung der Verarbeitungsgeschwindigkeit. Der Grund dafür ist die Ausführung der Simulation auf herkömmlicher Hardware. Die Erkenntnis ist demnach die Zunahme der Genauigkeit durch Quantenalgorithmen, bei verringerter Geschwindigkeit durch die Verwendung herkömmlicher Hardware. Die entscheidenden Potenziale liegen in der Integration von Quantencomputer in den Prozess, damit auch die Verarbeitungsgeschwindigkeit gesteigert werden kann (Chen et al., 2022).

In Anbetracht der Limitationen dieser Studie, wäre es vorteilhaft, den Datensatz in einer weiteren Studie zu erweitern, um eine größere Vielfalt an Stimmen und Aufnahmebedingungen einzuschließen. Hierdurch würde nicht nur die Generalisierbarkeit der Ergebnisse verbessert werden, sondern auch die Robustheit der Modelle

gegenüber unterschiedlichen akustischen Umgebungen verbessern. Des Weiteren wäre eine tiefere Erforschung der Integration von Quantencomputing in andere Bereiche des maschinellen Lernens und der künstlichen Intelligenz von Interesse. Die vorliegenden Ergebnisse deuten darauf hin, dass Quantentechnologien das Potenzial haben, bestehende Grenzen zu überwinden und neue Möglichkeiten in verschiedenen Anwendungsgebieten zu eröffnen. Zuletzt kann man in zukünftigen Studien auch die Entwicklung und Anwendung von Hybridmodellen, die traditionellen maschinellen Lernmethoden mit Quantencomputing-Techniken kombinieren. Bei solchen Modellen könnten die Vorteile beider Ansätze genutzt werden.

Literatur

- Ahmed, Sabbir/Mamun/Hossain (2021): Cochleagram based speaker identification using noise adapted CNN, IEEE Conference Publication | IEEE Xplore, [online] <https://ieeexplore.ieee.org/document/9667916>.
- Belyaev, Andrey K./Vera V. Kuzmina/Andrey A. Bychkov/Elena S. Yanakova/A. B. Хамухин (2018): The hierarchical high-speed neural network image classification algorithm for video surveillance systems, in: 2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIconRus), [online] doi:10.1109/eiconrus.2018.8317465.
- Braun, Daniel/Bertrand Georgeot (2006): Quantitative measure of interference, in: Physical Review A, vol. 73, no. 2, [online] doi:10.1103/physreva.73.022314.
- Cantiabala, Zahra/Hilman F. Pardede/Vicky Zilvan/Winita Sulandari/R. Sandra Yuwana/Ahmad Afif Supianto/Dikdik Krisnandi (2022): Deep Learning for Robust Speech Command Recognition Using Convolutional Neural Networks (CNN), in: IC3INA '22: Proceedings of the 2022 International Conference on Computer, Control, Informatics and Its Applications, [online] doi:10.1145/3575882.3575902.
- Chen, Xinmiao/Bo Jiang/Yongzheng Wu/Yongjin Ye (2022): A QCNN Algorithm Deployed on A Quantum Computer, in: 2022 International Conference on Computing, Communication, Perception and Quantum Technology (CCPQT), [online] doi:10.1109/ccpqt56151.2022.00074.
- Delgado, Francisco (2010): Quantum control on entangled bipartite qubits, in: Physical Review A, vol. 81, no. 4, [online] doi:10.1103/physreva.81.042317.
- Diefenbacher, Alexander/Robin Misia (2024): GitHub – alex3110-tech/Quantum_AI, GitHub, [online] https://github.com/alex3110-tech/Quantum_AI [abgerufen am 30.01.2024].
- Goularas, Dionysis/Sani Kamis (2019a): Evaluation of Deep Learning Techniques in Sentiment Analysis from Twitter Data, in: Quantum Machine Intelligence, Bd. 2, Nr. 1, [online] doi:10.1109/deep-ml.2019.00011.
- Goularas, Dionysis/Sani Kamis (2019b): Evaluation of Deep Learning Techniques in Sentiment Analysis from Twitter Data, in: 2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML), [online] doi:10.1109/deep-ml.2019.00011.
- Hema, T./Micheal Olaolu Arowolo (2023): Quantum Computing Significance on multidimensional data, in: Advances in systems analysis, software engineering, and high performance computing book series, pp. 217–230, [online] doi:10.4018/978-1-6684-6697-1.ch012.
- Henderson, Maxwell/Samriddhi Shakya/Shashindra Pradhan/Tristan Cook (2020): Quantum convolutional neural networks: powering image recognition with quantum circuits, in: Quantum Machine Intelligence, vol. 2, no. 1, [online] doi:10.1007/s42484-020-00012-y.
- Kerenidis, Iordanis (2019): Quantum algorithms for deep convolutional neural networks, arXiv.org, [online] <https://arxiv.org/abs/1911.01117>.
- Kharsa, Ruba/Ahmed Bouridane/Abbes Amira (2023): Advances in quantum Machine learning and Deep Learning for image Classification: a survey, in: Neurocomputing, vol. 560, p. 126843, [online] doi:10.1016/j.neucom.2023.126843.
- Krizhevsky, Alex/Ilya Sutskever/Geoffrey E. Hinton (2017): ImageNet classification with deep convolutional neural networks, in: Communications of the ACM, vol. 60, no. 6, pp. 84–90, [online] doi:10.1145/3065386.

- Li, YaoChong/Ri-Gui Zhou/Ruqing Xu/Jia Luo/Wenwen Hu (2020): A quantum deep convolutional neural network for image recognition, in: *Quantum Science and Technology*, vol. 5, no. 4, p. 044003, [online] doi:10.1088/2058-9565/ab9f93.
- Nielsen, Michael A./Isaac L. Chuang (2010): *Quantum computation and quantum information: 10th Anniversary Edition*, Cambridge University Press.
- O'Shea, Keiron (2015): An introduction to convolutional neural networks, arXiv.org, [online] <https://arxiv.org/abs/1511.08458>.
- Pan, Xiaoxuan/Zhide Lu/Wei-Ting Wang/Z. Hua/Yan Xu/Weikang Li/Wenli Cai/Xuegang Li/Haiyan Wang/Yipu Song/Chang-Ling Zou/Dong-Ling Deng/Luyan Sun (2023): Deep quantum neural networks on a superconducting processor, in: *Nature Communications*, vol. 14, no. 1, [online] doi:10.1038/s41467-023-39785-8.
- Rajesh, Varadi/Umesh Parameshwar Naik/Mohana (2021): Quantum Convolutional Neural Networks (QCNN) Using Deep Learning for Computer Vision Applications, in: *2021 International Conference on Recent Trends on Electronics, Information, Communication & Technology (RTEICT)*, [online] doi:10.1109/rteict52294.2021.9574030.
- Rietsche, Roman/Christian Dremel/Samuel Bosch/Léa Steinacker/Miriam Meckel/J. M. Leimeister (2022): Quantum computing, in: *Electronic Markets*, vol. 32, no. 4, pp. 2525–2536, [online] doi:10.1007/s12525-022-00570-y.
- Sachdeva, Kumud/Rajan Sachdeva/Himanshu Gupta (2023): Quantum Computing in Image Processing, in: *Quantum Computing in Image Processing*, [online] doi:10.3233/arde221232.
- Sanders, Barry C. (2023): Quantum computing for data science, in: *Journal of Physics: Conference Series*, vol. 2438, no. 1, p. 012007, [online] doi:10.1088/1742-6596/2438/1/012007.
- Stoos, Veit/Martin Ulmke/Felix Govaers (2022): Quantum computing for applications in data fusion, in: *IEEE Transactions on Aerospace and Electronic Systems*, pp. 1–11, [online] doi:10.1109/taes.2022.3212026.
- Thejha, B/S Yogeswari/A Vishalli/J. Jeyalakshmi (2023): Speech Recognition Using Quantum Convolutional Neural Network, in: *2023 Eighth International Conference on Science Technology Engineering and Mathematics (ICON-STEM)*, [online] doi:10.1109/iconstem56934.2023.10142793.
- Tripathy, B. K./Apoorv Singh (2023): Role of Quantum computing in a data analytics environment, in: *Advances in computational intelligence and robotics book series*, pp. 235–254, [online] doi:10.4018/978-1-6684-6821-0.ch014.
- Viamontes, George F./Igor L. Markov/John P. Hayes (2003): Improving Gate-Level simulation of quantum circuits, in: *Quantum Information Processing*, vol. 2, no. 5, pp. 347–380, [online] doi:10.1023/b:qinp.0000022725.70000.4a.
- Villalba-Diez, Javier, [ProfH4] (2021): GitHub – ProfH4/Papers_with_code_Quantum-Convolution-enhance-Deep-Learning-Stability-and-Performance: Papers_with_code_, GitHub, [online] https://github.com/ProfH4/Papers_with_code_Quantum-Convolution-enhance-DeepLearning-Stability-and-Performance[abgerufen am 30.01.2024].
- Villalba-Diez, Javier/Joaquín Ordieres-Meré/Ana González-Marcos/Aintzane Soto Larzabal (2022): Quantum Deep learning for steel industry computer vision quality control., in: *IFAC-PapersOnLine*, vol. 55, no. 2, pp. 337–342, [online] doi:10.1016/j.ifacol.2022.04.216.
- Wang, Jian/Han Wang/Yan Song (2017): Quantum Endpoint Detection based on QRDA, in: *International Journal of Theoretical Physics*, vol. 56, no. 10, pp. 3257–3270, [online] doi:10.1007/s10773-017-3493-5.
- Wen, Jie/Shuang Cong/Xubo Zou (2012): Realization of quantum hadamard gate based on Lyapunov method, *IEEE Conference Publication | IEEE Xplore*, [online] <https://ieeexplore.ieee.org/document/6359443>.
- Yamashita, Rikiya/Motohiro Nishio/Richard Kinh Gian/Kaori Togashi (2018): Convolutional neural networks: an overview and application in radiology, in: *Insights Into Imaging*, vol. 9, no. 4, pp. 611–629, [online] doi:10.1007/s13244-018-0639-9.