

大学授業データ分析における量子機械学習クラスタリング手法の適用可能性 検討

村上 祐子¹⁾, 稲垣 知宏¹⁾

1) 広島大学 情報メディア教育研究センター

yuk0mura@hiroshima-u.ac.jp

Exploring the Applicability of Quantum Machine Learning Clustering in University Course Data Analysis

Yuko Murakami¹⁾, Tomohiro Inagaki¹⁾

1) Information Media Center, Hiroshima Univ.

概要

本研究では、大学授業における教育データ分析に量子機械学習 (Quantum Machine Learning, QML) を導入し、その適用可能性を検討した。2025 年度前期に開講された「情報・データ科学入門」授業の履修者 176 名を対象に、計 2 回分の授業における動画視聴量および小テスト得点から 4 特徴量を抽出してクラスタリングを行った。古典的手法として K-means、量子手法として Qiskit による ZFeatureMap 埋め込みと KernelKMeans を用い、角度スケール γ を調整した。その結果、古典 $k = 4$ がシルエット係数 0.288 で最良、量子 $k=6$ は kernel シルエット 0.222 を示した。Adjusted Rand Index は 0.37 であり、量子手法は古典とは異なる切り分けを高安定に提供することが確認された。さらに、学習成果 (Δ score) のクラス間差は統計的に有意であり、 $C3 \gg C0 \approx C2 \gg C1$ の序列が得られた。回帰分析により、 $C1$ 群は動画視聴量の増加が学習の伸びに直結する群であることが示され、一方で高得点層では視聴増加が伸びに結びつかない傾向が明らかになった。以上より、古典クラスタリングは学習者全体の大枠を把握するのに適し、量子クラスタリングは同一学力帯に潜む異質性を抽出する補助的視点を提供することが分かった。本研究は、授業運営における介入方針 (誰に、どの施策を、どの強さで実施するか) の具体化に資する知見を提示するとともに、教育データ分析における量子手法の可能性と課題を示すものである。

1 はじめに

近年、大学教育では学習管理システム (LMS) やオンライン授業支援ツールの普及に伴い、授業活動や成績に関する多様かつ大量の教育データが蓄積されている。これらのデータを活用し、学習者特性や行動パターンを明らかにする研究は数多く行われてきた。たとえば、石川ら (2014) は LMS に蓄積された多次元学習履歴データを K-means クラスタリングと自己組織化マップ (SOM) で分析し、学習者の特性把握に役立てた [1]。また、永田ら (2015) は MOOC の大規模学習ログをクラスタリングし、受講者を学習行動の異なる 4 類型に分類した [2]。Siemens and Baker (2012) は学習分析と教育データマイニングの関係を論じ、両者の協調によって教育実践に資することを示した [3]。これらの事例は、クラスタリングなどの機械学習手法が教育実践に有用な知見をもたらすことを示している。

一方で、既存の機械学習・統計的手法には限界も指

摘されている。石川ら (2014) は、多次元かつ複雑な学習ログデータでは従来の分析手法で適切なパターン抽出が困難となる場合があることを報告している。また、Camargo ら (2009) は PAC 分析とテキストマイニングを組み合わせることで、単一手法では捉えきれない学習動機の構造を明らかにできることを示し、分析手法の多様化の必要性を示唆した [4]。さらに、石川・石本 (2023) は、退学予測モデルの開発において機械学習が有効である一方、モデル精度や特徴量選択に課題が残ることを報告している [5]。

こうした背景から、より高次元かつ複雑な構造を持つ教育データに対して新たな分析手法を導入することは、学術的にも実践的にも意義がある。量子計算は並列性と確率性を活用し、特定の問題において古典計算機を超える計算効率を発揮する可能性が指摘されている [6]。特に量子機械学習 (Quantum Machine Learning, QML) は、クラスタリングや分類などの教育データ分析において、従来手法では見落とされがちなパターンを探索できる可能性を秘めている。こうし

た展望は、量子機械学習の包括的レビュー [7] においても指摘されている。

本研究では、授業で得られた学生データに対し、Qiskit を用いた量子クラスタリングアルゴリズムを適用し、その有効性と課題を初期的に検証することを目的とする。

2 方法

2.1 対象データ

広島大学の医学部、歯学部、薬学部、法学部に所属する初年次学生 176 名であり、いずれも共通科目「情報・データ科学入門」を受講した学生を対象とした。

特徴量は、授業第 1 回目の動画視聴量 (video_c1) とその内容に関する小テスト得点 (test_c1)、また、第 6 回動画視聴量合計 (video_c2_total) とその内容に関する小テスト得点 (test_c2) の計 4 種類を用いた。第 6 回講義は 3 本の動画で構成されているが、本研究では総視聴量を合計し、特徴量を簡素化したうえで分析を行った。動画視聴量には log1p 変換を適用し、全特徴量は標準化 (StandardScaler) によってスケージングを行った。

2.2 アルゴリズム

比較対象の古典的手法として KMeans を用いた。量子クラスタリングでは、Qiskit の ZFeatureMap (reps=1) によって特徴を量子状態に埋め込み、忠実度に基づく量子カーネルを構築した。得られたカーネル行列を入力として KernelKMeans [8] を適用した。実装には Qiskit Machine Learning ライブラリ [9] を用いた。類似の QML 手法は特徴空間の表現力を拡張する研究としても報告されている [10]。角度スケールパラメータ γ を 0.5, 1, 2, 3 の範囲で調整し、 $\gamma = 0.5$ において最良の分離が確認された。

量子特徴写像 (ZFeatureMap) は、入力ベクトル $x \in \mathbb{R}^n$ を量子状態 $|\phi(x)\rangle$ に写像し、その際に重ね合わせや干渉を利用して古典空間より高次元の特徴表現を生成する。

二つのデータ x_i, x_j の類似度は、量子状態の内積として

$$K(x_i, x_j) = |\langle \phi(x_i) | \phi(x_j) \rangle|^2$$

で定義される。これを基に導かれる量子カーネル距離は

$$d_\phi(x_i, x_j) = \sqrt{2(1 - K(x_i, x_j))}$$

であり、「二つの状態がどの程度異なるか」を直感的に測る指標となる。すなわち、重ね合わせが近いほど距

離は小さく、干渉が異なるほど距離は大きくなる。この性質によって、従来のユークリッド空間では見えにくい非線形なパターンを抽出できる可能性がある。

2.3 評価指標

クラスタの分離度はシルエット係数を用いて評価し、古典手法ではユークリッド距離、量子手法では量子カーネル距離 ($d_\phi = \sqrt{2(1 - K)}$) を基準とした。また、古典クラスタと量子クラスタの対応関係を明らかにするため、Adjusted Rand Index (ARI) を算出した。さらに、量子クラスタリングの安定性を検証するため、初期値を変化させてクラスタラベルの一致度 (ARI) を計測した。以降では、古典クラスタを C0, C1, ..., 量子クラスタを Q0, Q1, ... と表記する。本研究での回帰分析は、各クラスタごとに独立に単回帰を行ったのではなく、クラスタをカテゴリ変数として投入し、 Δ_{access} との交互作用および test01 を共変量に含めた多変量線形回帰モデルに基づいている。

3 結果

3.1 クラスタリング性能の比較

古典的クラスタリングでは $k = 4$ のときにシルエット係数 (Euclid) が 0.288 と最良であった。一方、量子クラスタリングでは、 $\gamma = 0.5$ を用いた KernelKMeans により $k = 6$ で kernel シルエット 0.222 が得られた。古典クラスタリング、量子クラスタリングの結果を PCA で可視化した散布図をそれぞれ図 1, 2 に示す。古典と量子のクラスタラベル間の一致度は $\text{ARI}=0.37$ と部分的に対応するが、量子側は異なる軸で安定した切り分けを行っていた (初期値感度 $\text{ARI}=0.89 \pm 0.11$)。

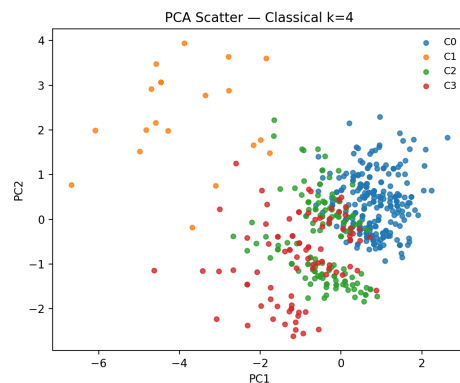


図 1 古典的クラスタリング ($k = 4$) の結果を PCA で可視化した散布図

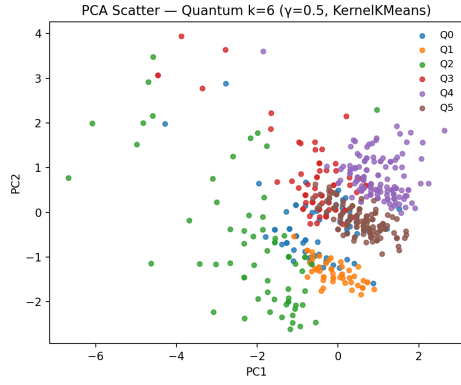


図2 量子クラスタリング ($\gamma = 0.5, k = 6$) の結果をPCAで可視化した散布図

3.2 学習成果 (Δ score) のクラスタ差

クラスタ間の学習成果 (Δ score) を比較したところ、Kruskal-Wallis 検定で有意差が確認された ($H = 251.8, p \approx 2.6 \times 10^{-54}$)。効果量 (Cliff's δ) からは、おおむね $C3 \gg C0 \approx C2 \gg C1$ の序列が得られた (表1、表2、図3)。

クラスタごとの平均 Δ score を図示した結果、古典クラスタでは C1 が、量子クラスタでは Q5 が特に伸

表1 古典クラスタ (C0-C3) における Kruskal-Wallis 検定結果

指標	H	p
Δ score	251.8	2.62e-54
Δ access	79.1	4.83e-17

表2 古典クラスタ間の Cliff's δ (Δ score)

	C0	C1	C2	C3
C0	-	0.83	0.03	-0.99
C1	-	-	-0.82	-1.00
C2	-	-	-	-0.99
C3	-	-	-	-




図3 古典的クラスタリング ($k = 4$) におけるクラスタ別 Δ score (平均 \pm 95%CI)

表3 量子クラスタ (Q0-Q5) における Kruskal-Wallis 検定結果

指標	H	p
Δ score	152.7	3.52e-31
Δ access	234.0	1.46e-48

表4 量子クラスタ間の Cliff's δ (Δ score)

	Q0	Q1	Q2	Q3	Q4	Q5
Q0	-	0.93	0.39	0.94	0.93	0.93
Q1	-	-	-0.42	-0.12	-0.07	-0.18
Q2	-	-	-	0.37	0.39	0.33
Q3	-	-	-	-	0.07	-0.04
Q4	-	-	-	-	-	-0.12
Q5	-	-	-	-	-	-




図4 量子クラスタリング ($\gamma = 0.5, k = 6$) におけるクラスタ別 Δ score (平均 \pm 95%CI)

びの小さい群として特徴付けられた (表3、4、図4)。また、量子クラスタにおいても Kruskal-Wallis 検定で有意差が確認され、古典とは異なる切り分けが得られた。

3.3 学習行動 (Δ access) との関係

次に、クラスタ間のアクセス変化 (Δ access) を比較した。Kruskal-Wallis 検定の結果、有意差が確認され ($H = 79.1, p \approx 4.8 \times 10^{-17}$)、特に C1 のアクセス量が他クラスタに比べて小さいことが明らかになった (表5)。これは前節で示した Δ score の低さに対応しており、「C1 はアクセス増が不足している群」と解釈できる。

さらに回帰分析 (Δ score \sim Δ access * cluster + test01) の結果、C1 群のみ「 Δ access 増加 \rightarrow Δ score 増加」の傾きが有意に正であった ($\beta \approx 0.79, p = 0.004$, 表6、図5)。

量子クラスタでは Q2、Q4 において有意な傾向が確認され、古典クラスタとは異なる切り分け方の違いが示唆された。これを裏付けるペアワイズ効果量の結果

を表7に示す。初期得点 (test01) と Δscore の間には有意な負の関係 ($\beta \approx -0.87, p < .001$) があり、高得点層ではアクセス増加が必ずしも学習の伸びに結びつかないことが示された。

量子クラスタの回帰分析では、Q2 ($\beta_{\Delta\text{access}} = 0.53, p = 0.001$) および Q3 ($\beta = 0.85, p = 0.018$) で有意な正の傾向が確認された。一方、test01 は有意に負 ($\beta = -0.80, p < .001$) であり、高初期得点層ではアクセス増加が伸びに直結しにくい傾向が示唆された (表8、図6)。




図5 古典的クラスタリング ($k = 4$) における Δaccess と Δscore の関係 (回帰直線を重ね描き、色はクラスタを示す)




図6 量子クラスタリング ($\gamma = 0.5, k = 6$) における Δaccess と Δscore の関係 (回帰直線を重ね描き、色はクラスタを示す)

表5 古典クラスタ間の Cliff's δ (Δaccess , 行 - 列)

	C0	C1	C2	C3
C0	-	0.85	0.39	0.22
C1	-	-	-0.55	-0.65
C2	-	-	-	-0.17
C3	-	-	-	-

表6 回帰分析 (古典クラスタ): $\Delta\text{score} \sim \Delta\text{access} \times C + \text{test01}$

項目	推定値	標準誤差	z	p
基準クラスタ (C0) の推定値				
切片 (C0)	7.320	0.355	20.592	0.000
傾き (C0)	0.018	0.016	1.137	0.255
クラスタの切片差 (基準=C0)				
C1	-7.031	0.369	-19.034	0.000
C2	-0.029	0.110	-0.266	0.790
C3	0.568	0.238	2.386	0.017
クラスタの傾き差 (基準=C0)				
C1	0.793	0.277	2.864	0.004
C2	-0.026	0.027	-0.958	0.338
C3	0.012	0.035	0.359	0.719
test01	-0.867	0.042	-20.773	0.000

注) 多変量回帰 (交互作用付き)。各「差」は基準との差。

表7 量子クラスタ間の Cliff's δ (Δaccess , 行 - 列)

	Q0	Q1	Q2	Q3	Q4	Q5
Q0	-	-0.52	0.28	0.74	-0.02	-0.36
Q1	-	-	0.75	1.00	0.55	0.26
Q2	-	-	-	0.58	-0.34	-0.64
Q3	-	-	-	-	-0.86	-1.00
Q4	-	-	-	-	-	-0.39
Q5	-	-	-	-	-	-

4 考察

本研究の結果から、古典的クラスタリング (C0-C3) は全体の大枠を把握するうえで有効であり、一方で量子クラスタリング (Q0-Q5) は古典では抽出されなかった別軸の安定した切り分けを提供することが示唆された。特に、古典クラスタ C1 は初期得点が低く学習の伸びも小さいが、動画視聴量の増加に対して伸びが敏感に反応する群である。一方、量子クラスタの Q5 も同様に伸びが小さい群として抽出されており、両手法で異なる観点からリスク群を特定できることが分かった。

C3 はもともと高い伸びを示しており、視聴量の増加よりも発展的課題や自己テストを優先する方が望ましい。C0 や C2 については視聴増加が伸びに直結しにくく、演習設計や即時フィードバック、ピア活動の充実といった質的改善が必要である。

量子クラスタリングの導入は、古典的手法と組み合わせることで、同一学力帯の中に潜む異質性を抽出し、

表8 回帰分析(量子クラスタ): $\Delta\text{score} \sim \Delta\text{access} \times Q + \text{test01}$

項目	推定値	標準誤差	z	p
基準クラスタ (Q0) の推定値				
切片 (Q0)	7.379	0.503	14.666	0.000
傾き (Q0)	0.053	0.051	1.045	0.296
クラスタの切片差 (基準=Q0)				
Q1	-0.504	0.640	-0.787	0.432
Q2	-2.303	0.668	-3.447	0.000
Q3	-0.944	0.601	-1.572	0.116
Q4	-0.672	0.606	-1.110	0.267
Q5	-0.767	0.576	-1.330	0.184
クラスタの傾き差 (基準=Q0)				
Q1	-0.096	0.063	-1.529	0.126
Q2	0.530	0.166	3.194	0.001
Q3	0.847	0.359	2.361	0.018
Q4	-0.056	0.059	-0.953	0.341
Q5	-0.008	0.057	-0.144	0.886
test01	-0.797	0.102	-7.822	0.000

注) 多変量回帰 (交互作用付き)。各「差」は基準との差。

支援メニューをさらに精緻化する補助的視点を提供できる。したがって、教育実務においては古典クラスタを基盤としつつ、量子クラスタを補助的に併用する運用が有効であると考えられる。

教育的な観点からは、量子クラスタリングを組み合わせることで、同一学力帯の中に潜む異質な群を早期に発見できる可能性がある。例えば、動画視聴量の増加が学習成果に直結する群を特定できれば、オンデマンド教材の提示方法や小テスト設計を調整するなど、対象を絞った介入が可能となる。一方で、高得点層に対しては追加動画の提供よりも演習課題やピア活動の充実を優先するなど、学習者特性に応じた支援設計に資する。このように、クラスタリング結果を授業デザインに接続することで、「誰に、どの施策を、どの強さで」適用するかという意思決定の精緻化が期待される。

本研究の限界は以下の通りである。対象としたのは広島大学の医学部、歯学部、薬学部、法学部に所属する初年次学生に限定されており、他学部の学生に対する一般化には慎重が必要である。さらに、本研究で用いた量子クラスタリングは Google Colab 上で Qiskit シミュレータを用いて実行したものであり、量子ハードウェア固有のノイズやリソース制約を考慮していない。加えて、クラスタリングに必要なカーネル行列の計算は計算コストが高く、大規模データへの適用には

スケーラビリティの改善が不可欠である。今後は、実機環境での検証、効率的なカーネル近似手法の導入、さらには他大学データを用いた検証を進めることで、教育データ分析における量子手法の汎用性を確認していく必要がある。

5 まとめ

本研究では、大学授業データに対して量子クラスタリング手法を適用し、古典手法との比較を行った。その結果、古典 $k=4$ が最良の分離を示す一方で、量子 $k=6$ は高安定に別軸の切り分けを提供することが確認された。学習の伸びはクラスタ間で大きく異なり、特に C1 群は動画視聴の促進により伸びが改善される可能性が示された。

これらの知見は、授業運営における「誰に、どの施策を、どの強さで」介入すべきかという意思決定を具体化する上で有用である。今後は、A/B テスト型の介入実験や特徴量の拡張、公平性の検証を進め、量子手法の教育データ分析における実用的可能性をさらに探究していく必要がある。

謝辞

本研究は JSPS 科研費 JP24K16756(Y.M), JP23K25704, JP23K11349 (T.I.) の助成を受けたものです。

参考文献

- [1] 石川晶子, 小川賀代, ピトヨ・ハルトノ, 学習履歴データを活用した学習者の特性抽出手法の検討, 教育システム情報学会誌, 31, 2, 185-196, 2014.
- [2] 永田裕太郎, 村上正行, 森村吉貴, 棕木雅之, 美濃導彦, MOOC における大規模学習履歴データからの受講者の学習様態獲得, 人工知能学会 先進的学習科学と工学研究会 (SIG-ALST) 研究会資料, 73, 25-30, 2015.
- [3] Siemens, G., & Baker, R. S. (2012). Learning analytics and educational data mining: towards communication and collaboration. Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK' 12), pp. 252-254.
- [4] Luiz Antonio Camargo, 吉長裕司, 金川明弘, 川畑洋昭, PAC 分析とテキストマイニング手法を併用した学習動機の構造分析, 教育システム情報学会誌, 25, 4, 371-381, 2009.

- [5] 石川千温, 石本翔真, 機械学習を用いた退学予測に基づくエンrollmentマネジメントシステムの構築, 情報処理学会論文誌デジタルプラクティス, 4, 2, 202-211, 2023.
- [6] Maria Schuld, Ilya Sinayskiy, Francesco Petruccione, An introduction to quantum machine learning, Contemporary Physics, 56, 2, 172-185, 2015.
- [7] Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N., Lloyd, S., Quantum machine learning, Nature, 549, 195–202, 2017.
- [8] Inderjit S. Dhillon, Yuqiang Guan, Brian Kulis, Kernel k-means: Spectral clustering and normalized cuts, Proceedings of the 10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 551–556, 2004.
- [9] Qiskit Machine Learning. <https://qiskit.org/ecosystem/machine-learning/>
- [10] Maria Schuld, Nathan Killoran, Quantum machine learning in feature Hilbert spaces, Physical Review Letters, 122(4), 040504, 2019.