

量子×AIで宇宙の突発的な異常エネルギー解放現象を検出

川室 太希^{*1, 4}
Kawamuro Taiki

山田 真也^{*2}
Yamada Shinya

山田 智史^{*3}
Yamada Satoshi

長瀧 重博^{*4}
Nagataki Shigehiro

松浦 俊司^{*4}
Matsuura Shunji

酒井 優輔^{*2}
Sakai Yusuke

1. 躍動する宇宙を量子計算機で観る

1.1 突発的に明るくなる天体現象の探査

宇宙では日々、超新星爆発やブラックホールへの急激な物質降着に伴うフレア等、突発的なエネルギー解放現象が起こっている。これらは、宇宙の構造形成や極限環境における物理過程を理解するうえで重要な手がかりとなる。更に、突発現象の中から研究者が予期していなかった現象が見つかることもあり、「異常変動」を発見すること自体が新しい学問の入口になりうる。

近年の天文学では、空の広い領域を高感度かつ高頻度で観測し、突発現象をできるだけ早く検出したうえで、迅速な追観測によってその性質を詳細に調べる研究がますます重視されている。実際、可視光で広域の時間変動天体を監視するツビッキー掃天観測施設（米国）や、近年稼働が進むベラルービン天文台（チリ）によって、宇宙の時間変動を記録した膨大なデータが取得されつつある。加えて将来は、電波干渉計 Square Kilometre Array や X 線宇宙望遠鏡 NewAthena 等、他の波長域でも大規模な時間変動データが供給されると期待されている。

このような時間変動に着目する時間軸天文学（タイムドメイン天文学）では、取得されるデータ量が増大の一途をたどっており、変動天体や突発現象を自動的に検出する手法の開発が重要な研究課題の1つとなっている。その有力なアプローチとして機械学習が注目され、実際に突発現象の検出等に活用されてきた¹⁾。具体的には、光度曲線を複数のタイ

プに分類するだけでなく、特徴空間上で外れ値となる事例を手がかりに新たな変動現象を探索する試みや、検出された突発現象候補が本物か偽検出かを判定する作業にも機械学習が利用されている。

1.2 量子計算機

機械学習の性能を押し上げる手段としての1つとして、量子計算機の活用が注目されている。量子計算機は、情報の基本単位として「量子ビット (qubit)」を用いる。量子ビットは0と1のどちらか一方に固定される古典ビットと異なり、0と1が重なり合った状態（重ね合わせ）をとれる点が大きな特徴である。状態は最も基本的には、 $|\psi\rangle = \alpha|0\rangle + \beta|1\rangle$ ($|\alpha|^2 + |\beta|^2 = 1$) と書け、観測したときに0が出る確率は $|\alpha|^2$ 、1が出る確率は $|\beta|^2$ で与えられる。量子ビットの数が増えるほど表現できる状態の種類が指数関数的に増加し、複雑な情報を効率よく扱える可能性が生まれる。更に量子ビット同士が強く結びつくエンタングルメント（量子もつれ）や、確率の重なりが結果に影響する干渉といった、古典計算にはない性質が存在する。これらは、計算の高速化だけでなく、データの特徴を捉える特徴空間をより豊かに表現できる可能性があると考えられている。ただし現時点で利用可能な量子計算機は、ノイズの影響を受けやすい「NISQ (Noisy Intermediate-Scale Quantum; ノイズを伴う中規模量子計算機)」段階にあり、計算結果が量子ノイズに左右されやすいという課題がある。そのため、量子計算が現実の問題で古典計算機の結果をどの程度上回るのかは、議論




図1 (a) Bloch 球上での $|0\rangle$ 状態。(b)~(d) $R_Y(\pi/2)$, $R_Z(\pi/2)$, $R_X(-\pi/2)$ ゲートを逐次作用させた結果

の余地が多々あり、世界的に活発な検証が続けられている。

この量子ビットを用いた量子計算には複数の方式がある。代表例がゲート型（回路モデル）とイジング型（量子アニーリング等）である。ゲート型は、量子ゲートと言われるものを組み合わせて回路を構成し、量子ビットに作用させることで状態を変化させ、計算を進める方式である。古典計算機の論理ゲートに相当する役割を量子ゲートが担うため、汎用的な計算が可能であると考えられている。一方のイジング型は、解きたい課題をスピンの相互作用で表されるイジング模型のエネルギー（目的関数）として定式化し、そのエネルギーをできるだけ小さくする状態を探索する方式である。組合せ最適化の枠組みと相性がよいとされている。

本稿で着目するゲート型量子計算では、量子ゲートは数学的には確率を保つ変換（ユニタリ変換）として表される。直感的には、量子ビットの状態を Bloch 球上の点（ベクトル）として可視化したとき（図1）、そのベクトルを回転させる操作として理解できる。例えば Pauli X, Y, Z や回転ゲート $R_X(\theta)$, $R_Y(\theta)$, $R_Z(\theta)$ は、それぞれ特定の軸まわりの回転に対応する。多くの量子ゲートのうち、Hadamard (H) ゲートは重ね合わせを作る代表的な操作であり、 $|0\rangle \rightarrow (|0\rangle + |1\rangle) / \sqrt{2}$ のように状態を変換する。更に、2つの量子ビットを同時に操作する CNOT ゲートは、一方（制御側）の状態に応じて他方（標的側）

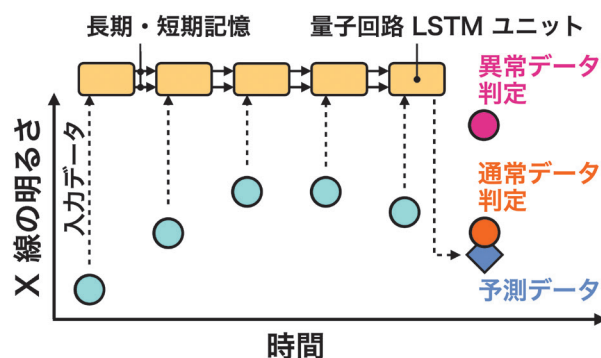


図2 LSTM の概要

データを順次入力しつつ、並列して2種類の記憶（短・長期記憶）を更新、伝達していく。最終的に予測を行い、実際のデータの比較から異常検知を行う

を反転させる操作であり、量子ビット間の強い相関（量子もつれ）を生成する基本的なゲートの1つである。

2. 量子機械学習を用いた突発天体现象探査

2.1 量子版長・短期記憶と宇宙の X 線変動データベース

以上の背景を踏まえ、本研究では天文学における新たな試みとして、量子計算機概念を取り入れた量子機械学習（Quantum Machine Learning; QML）モデルを構築し、過去約20年間にわたり蓄積されてきた宇宙 X 線放射の時間変動データから、特異な変動を「突発現象（トランジェント）」として自動的に同定できるかを検証した²⁾。なお、本研究で用いる量子計算は実機ではなく、量子回路シミュレーションにより実行した。

QML モデルとしては、時系列データの予測に広く用いられてきた長・短期記憶（Long Short-Term Memory; LSTM）を量子回路で拡張した「量子版 LSTM (Quantum LSTM)」を実装して用いた^{3,4)}（図2）。LSTM は、再帰型ニューラルネットワーク（Recurrent Neural Network; RNN）の一種であり、基本的な RNN に比べて、内部の「記憶」を更新しながら長期的な情報を保持できる点に特徴がある。そのため、直前の情報（短期的な変化）だけでなく、より長い時間スケールの振る舞いも取り込みつつ、過去のデータにもとづいて将来の値を予測できる。

LSTM はこの性質から、株価予測や音声・文章の解釈、翻訳等、連続データを扱う多様な課題で利用

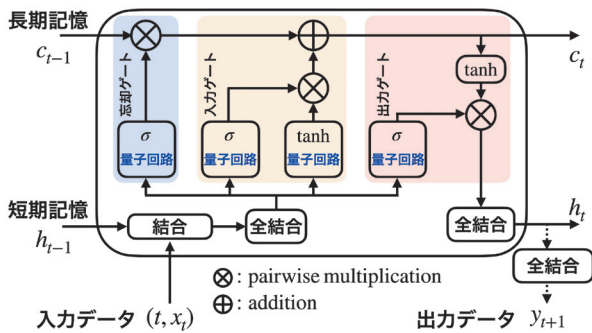


図3 量子 LSTM の概要

長期記憶, 短期記憶, そして入力データ (ベクトル) をインプットに, 3種類のゲートを通じて最終的に, 次のステップに情報を渡すもしくは予測値を返す。σはシグモイド関数で, tanhはハイパボリックタンジェント関数を表す

されてきた。本研究ではこの予測能力を利用し, モデルが学習した「通常の振る舞い」から大きく外れる変動を突発現象の候補として検出する枠組みを採用する。

突発現象の探索に用いる実データとして, 本研究では, X線宇宙望遠鏡「XMM-Newton」の大規模カタログである XMM-Newton Serendipitous Source Catalog, Fourteenth Data Release (4XMM-DR14) に収録された多数の光度曲線を対象とした^{5,6)}。XMM-Newtonは, 0.2~12 keVの軟X線帯域で大きな有効面積を持つ3つの検出器と, 直径約30分角の広い視野を備えたX線天文衛星であり⁷⁾, 長年にわたって効率よくX線データを蓄積してきた。その結果, 4XMMカタログはX線天文学における最大級のデータベースの1つとなっている。このような大規模データから突発現象を網羅的に探索するには, 人手による確認だけでは限界があり, 自動検出技術が不可欠である。

2.2 量子 LSTM の実装

量子 LSTM は, 古典的な LSTM の枠組み (短期記憶・長期記憶を更新しながら時系列を予測する仕組み) を保ちつつ, 内部の一部計算を量子回路で置き換えたハイブリッド型 (古典計算+量子計算) のモデルである (図3)。具体的には, 古典 LSTM の内部にある「忘れる/取り込む/出力する」を制御するゲートでは, 入力と過去の状態を全結合層 (線形変換) に通してゲートの開き具合を計算するが, 本研究ではこの全結合層に相当する変換を量子変分回路 (Quantum Variational Circuit; QVC) に置き換え

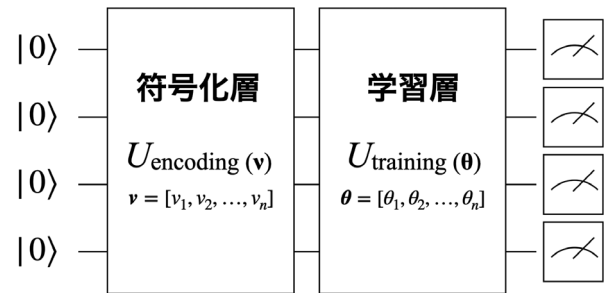


図4 量子変分回路 (QVC) の概要

図3の青字で示されている量子回路の部分に相当する。始状態が|0>の4つのqubitに対して, 実データ(v)の情報を符号化層で埋め込み, 学習層で調整可能なパラメータで変化させる

た (図4)。

QVCは, 入力データの情報を量子ビットに埋め込む「符号化層」と, 調整可能なパラメータ (回転角) を含む「学習層」から構成される。量子ビットをQVCに通した後に測定を行い, 期待値 (実数) として出力を取り出す。この出力が目的 (本研究では光度曲線の予測誤差) を改善するように, 回路内のパラメータを反復的に更新する。

具体的な処理の流れは図3のとおりである。(1)各時刻の観測値 (明るさ) と時刻情報, 並びに直前までの内部状態 (短期記憶) を, 量子回路に入力できる形へ古典側の全結合層で整形する。(2)量子回路内では, 回転ゲートや2量子ビットゲート (例: CNOT) を組み合わせ, 入力に応じて量子状態を変換する。(3)回路の出力を測定によって実数値 (期待値) として取り出し, これを LSTM のゲート計算の出力として用いる。以上により, 量子回路の出力を用いて LSTM の記憶更新と予測が行われる。

学習は通常の機械学習と同様に, 予測誤差が小さくなるようにパラメータを更新することで行う。すなわち, 古典側のパラメータに加えて, 量子回路に含まれる可変パラメータ (回転角) も最適化の対象とし, 学習データに対する予測が改善するよう反復的に調整する。

2.3 量子 LSTM の性能検証: 有効次元

量子 LSTM の有用性を議論するうえで, 「量子回路を入れれば表現力が必ず向上する」と単純に期待するだけでは不十分である。同じパラメータ数であっても, 回路の構成やデータの性質によって, 実際に表現できる関数の多様さ (モデルが取り得る振

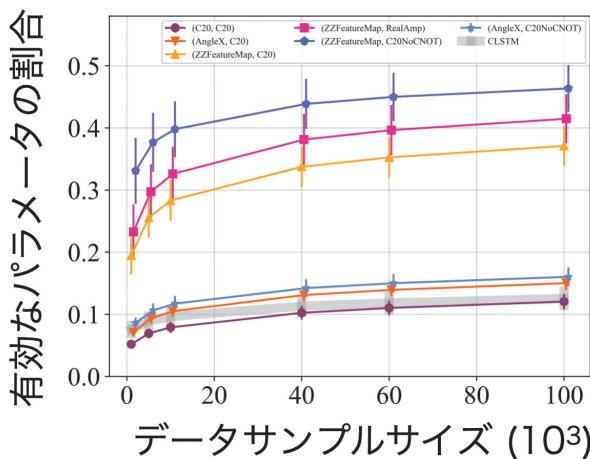


図5 有効次元（実効的な自由度）のデータサンプルサイズ依存性

6種類の異なるQVCを用いた量子LSTMの結果と、古典LSTMの結果(灰色)を示す

る舞いの幅)は大きく変わり得るからである。そこで本研究では、量子回路を組み込んだモデルがデータに対してどれだけ多様な表現を実質的に実現できるかを定量的に把握するため、有効次元 (effective dimension) を評価指標として用いた。有効次元は単なる自由パラメータ数ではなく、パラメータの変化が出力にどれほど影響するか(感度)を通して、モデルの「実効的な自由度(表現力)」を測る目安と捉えることができる。

本研究では、QVCの構成(回路の深さ、回転ゲートの配置、2量子ビットゲートによる相関の入れ方等)を6種類用意し、比較のために古典的LSTMも構築した。そして、各モデルについて、有効次元を複数のデータサイズに対して計算し比較した(図5)。一般に、データサイズが増えるほど見分けるべき構造が増えるため、有効次元もデータサイズに応じて変化し得る。

その結果、有効次元は回路設計に依存して増減し、量子LSTMが常に古典LSTMより大きな有効次元を持つわけではないことが分かった。一方で、特定の回路構成では有効次元が増大し、量子回路を組み込むことでモデルの表現力が高まり、より複雑な時系列データを表現できる可能性が示された。したがって、量子LSTMの利点は「量子であること」そのものよりも、データ特性に適した回路設計を行えるかに左右されると考えられる。

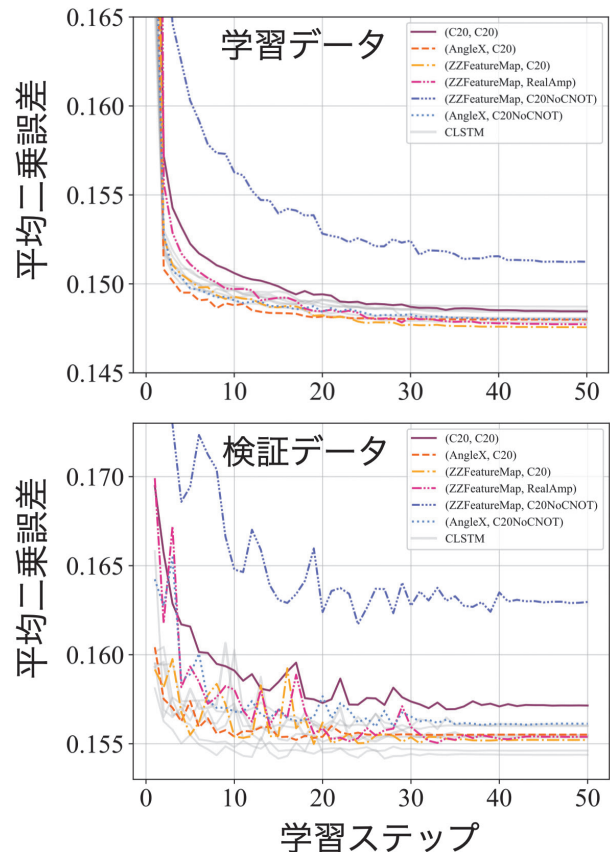


図6 6種類の異なるQVCを持つ量子LSTM (QLSTM) 及び古典LSTM (灰色) について、学習ステップに対する平均二乗誤差 (MSE; loss) の推移

上段は学習データ、下段は検証データに対する結果である

2.4 学習と損失関数

モデルの学習と性能評価には、「通常データ」と「異常データ」という2種類のデータセットが必要である。学習に主に用いる通常データとして、本研究では4XMMに多数含まれる典型的な変動天体である活動銀河核 (AGN) のX線光度曲線(ブラックホールへの質量降着に伴う不規則な変動)を模した光度曲線をシミュレーションで多数生成した。一方、異常データは、通常データに突発的なフレア成分を付加して作成した。ここでは、近年注目を集めている準周期的噴出 (Quasi-Periodic Eruptions; QPEs) に類似した、数時間から数日おきに繰り返し現れるフレアを例として用いた⁸⁾。

まず、通常データを用いて量子LSTMを学習させ、モデルが通常時の光度変化をどの程度再現できるかを確認した。学習では、各時刻の観測値 x_t に対する予測値 \hat{x}_t のずれが小さくなるように、古典側のパラメータに加えてQVC内の可変パラメータ(回転角)




図7 量子 LSTM による逐次予測の例

上段：シミュレーションした通常光度曲線（灰色）に対し、直前の 5ks を用いて逐次予測した結果。橙線はノイズなし、青線はノイズありの場合の予測値を示す。下部は観測値と予測値の差（残差）である。下段：異常フレアを含む光度曲線の場合。フレアが現れる時刻（～50ks）付近で残差が大きくなり、異常変動の存在を示す

も同時に更新する。予測精度を表す指標として、平均二乗誤差（Mean Squared Error; MSE）

$$MSE = \frac{1}{T} \sum_{t=1}^T (x_t - \hat{x}_t)^2 \quad (1)$$

を損失関数（loss）として用い、学習が進むほど loss が低下することを確認した（図6）。更に、学習に用いていない検証データに対しても loss が十分小さく、「見たことのない」通常光度曲線に対しても予測が可能であることが分かる。例として、直前の 5ks を用いて逐次予測した結果を図7上段に示す。

異常検知の基本は、「通常時の振る舞いを学習した予測器」を作り、その予測から大きく外れる変動を異常（突発現象候補）として拾い上げることである。本研究では、学習済みモデルの残差 $|x_t - \hat{x}_t|$ を異常度の指標とし、残差が顕著に増大する時刻（又は区間）を突発現象候補として同定した。異常データに対しては、フレアのタイミングで残差が大きくなることを期待され、実際に図7下段に示すように、異常フレア付近で顕著な増大が確認できる。




図8 量子 LSTM により異常フレアが検出された天体候補の内訳（種別別の数）

多くは恒星フレアに由来する可能性が示唆される一方で、約 1/3 は現時点で正体不明である

2.5 大規模 X 線光度曲線データベースへの適用：異常天体の抽出

4XMM-DR14 カタログに含まれる多数の X 線光度曲線に対して、異常候補の探索を行った。本研究ではデータ品質等の条件を満たすものに絞り、最終的に 40154 本の光度曲線を対象とした。各光度曲線について、学習済みの量子 LSTM で逐次予測を行い、観測値と予測値の差（残差）を計算した。そして、残差があらかじめ設定した閾値を超える光度曲線を、突発現象候補として抽出した。

その結果、量子 LSTM により 113 本の光度曲線が異常候補として検出された。同様の手順を古典 LSTM で適用した場合の候補数は 85 本であり、量子 LSTM の方がより多くの候補を拾い上げる結果となった。候補数が増えた要因としては、量子 LSTM が通常変動の学習に偏り過ぎることなく（過適合を起こしにくく）、異常的な振る舞いに対してより大きな残差を残しやすかった可能性が考えられる。

抽出された候補については既知天体カタログとの照合を行い、いくつかの候補は既知の変動天体（特に恒星フレア）と整合した（図8）。また、着目していた準周期噴出（QPE）に類似した事例や、超新星爆発で生じた衝撃波が星の表面に到達する際に現れる初期閃光（ショックブレイクアウト）等、稀な現象が含まれている可能性も示唆された。一方で、

有力な対応天体や既知現象が見つかっていない候補も存在する。これらは追加解析や追観測によって真の突発現象であるかを検証すべき対象であり、未だ認識されていない現象が含まれている可能性もある。

3. 展望：量子機械学習の発展と実社会への応用

本研究が示したのは、量子回路を組み込んだ時系列予測モデルが、実際の観測データに対しても異常候補の検出（一次スクリーニング）に利用できる可能性があることである。今後、時間領域天文学が更に本格化し、光度曲線データが飛躍的に増大するなかでは、人手だけに頼らずに候補を抽出・整理する自動解析の重要性が一層高まる。そのため、本研究のように量子計算機の活用も視野に入れつつ、機械学習モデルの表現力・頑健性・運用性を高める取り組みを継続することは重要である。

また、天文学は公開データが豊富で、かつ多様な変動現象を含むという特徴を持つ。このため、量子機械学習がどのような条件で有効となるのか、あるいはどの点がボトルネックとなるのかを検証するうえで格好の実験場となる。ここで得られる知見は将

来的に、天文学にとどまらず、他分野の計測データ解析へ波及する可能性がある。例えば、放射線の長期モニタデータや環境・設備監視データにおいて、「通常状態を学習し、そこから外れた兆候を早期に検出する」枠組みは共通しており、量子機械学習は大規模データ時代の異常検知技術として発展し得ると期待される。そしてより長期的には、異常検知に限らず、量子計算の応用がどこまで広がるのが最も楽しみである。

参考文献

- 1) Muthukrishna, D., *et al.*, *MNRAS.*, **517**, 393 (2022)
- 2) Kawamuro, T., *et al.*, *ApJ.*, **987**, 105 (2025)
- 3) Hochreiter, S., *et al.*, *Neural Comput.*, **9**, 1735 (1997)
- 4) Yen-Chi Chen, S., *et al.*, arXiv:2009.01783 (2020)
- 5) Webb, N. A., *et al.*, *A&A.*, **641**, A136 (2020)
- 6) Traulsen, I., *et al.*, *A&A.*, **641**, A137 (2020)
- 7) Jansen, F., *et al.*, *A&A.*, **365**, L1 (2001)
- 8) Arcodia, R., *et al.*, *Nature*, **592**, 704 (2021)

(*¹ 大阪大学, *² 立教大学, *³ ジュネーブ大学, *⁴ 理化学研究所)