



Title	グラフ構造を活用した解釈可能な脳波モデルの開発
Author(s)	小峠, 陸登
Citation	サイバーメディアHPCジャーナル. 2026, 16, p. 106-109
Version Type	VoR
URL	https://doi.org/10.18910/106248
rights	
Note	

The University of Osaka Institutional Knowledge Archive : OUKA

<https://ir.library.osaka-u.ac.jp/>

The University of Osaka

グラフ構造を活用した解釈可能な脳波モデルの開発

小峠 陸登

大阪大学 大学院情報科学研究科

1. はじめに

てんかんは一般に、脳神経ネットワークに生じる異常な発作現象として知られている [1,2]。脳領域間に生じる異常な結合関係は、しばしば発作の指標として機能し、発作検知の自動化を目的として、これらの神経ネットワーク構造を明示的に表現できるグラフニューラルネットワーク (GNN) を用いた研究が行われている [3,4,5]。特に、脳活動の時間的な変化を考慮するため、脳波信号を時間とともに変化するグラフの系列として捉える枠組みが注目されている。特に、再帰型ニューラルネットワーク

(RNN) などの時系列モデルと GNN を統合した動的 (dynamic) GNN と呼ばれる手法が提案されており、脳波に内在する時空間的特徴の学習に用いられている。これらの手法は、時間ステップごとにグラフ構造を表現し、その系列を逐次的に処理することで、脳状態やネットワーク構造の時間的な変化を捉え、発作検出精度の向上を可能にしている。しかし、グラフ表現と時系列表現を効果的に統合し、脳活動の時間変化を適切に捉えるには本質的に、以下の課題が存在する。

既存モデルの多くは動的なグラフ「モデル」を用いているものの、静的なグラフ「構造」を用いている場合が多い [3,4,5]。これらの手法では通常、初期の脳波データに基づいてチャンネル間の相関関係からグラフを事前に構築し、その構造をすべての時間ステップで共有する。この設計は、脳活動の空間構造が時間を通じて不変であるという仮定を暗黙的に置いている。一方で、図 1 に示すように、発作は脳内の異なる領域間において、神経細胞の同期化および非同期化が時系列的に進行する複雑なパターンを引き起こすことが知られている。




図 1：多次元脳波データとネットワークの変化

本研究ではまず、脳ダイナミクスを効果的に表現し、発作検出を高精度に行うために、脳ネットワークにおける進化的かつ動的な特性を効果的に学習する手法 EvoBrain を提案する。本研究の主な貢献は以下の通りである：

本研究では、神経科学的知見に基づき、2 ストリーム Mamba アーキテクチャ [6] とラプラシアン位置符号化を用いた GCN を統合する新しいモデル EvoBrain を提案する。EvoBrain は、動的 GNN ベースラインと比較して、AUROC で最大 23%、F1 スコアで最大 30%の性能向上を達成した。さらに、method は、既存の TAG モデルと比較して最大 17 倍高速である。

2. 提案手法

2.1 記号

本研究では、 N チャンネル、 T スナップショットからなる多次元脳波信号を、動的グラフ $G = (A, X)$ として定義する。ここで、 $A = (V, E)$ は動的なグラフ構造を表し、 A は $N \times N \times T$ の時間方向に拡張された隣接行列である。 V および E は、それぞれ脳波電極、すなわちノードと、エッジを表す。多くの既存研究では、重み付き隣接行列 A を $N \times N$ の行列として時間 T にわたって固定し、すべての脳波スナップショットが同一のグラフ構造を共有する設定が採用されている。この設定では、各時刻においてノード特

徴 H のみが逐次的に更新される。

一方、本研究では、各エッジ $e_{ij,t}$ が、時刻 t におけるチャンネル v_i と v_j の間の結合関係を表す。対応する隣接要素 $a_{ij,t}$ は実数値を取り、各時間ステップにおける 2 チャンネル間の結合強度を定量化する。 $e_{ij,t}$ が存在する場合、 $a_{ij,t}$ は非ゼロ値を取る。

2.2 動的グラフ構造

脳波の記録全体から単一の静的グラフを構築する代わりに、各スナップショットごとに脳波グラフを構築することを提案する。まず、脳波データを一定間隔で短い区間、すなわちスナップショットに分割し、チャンネル相関を計算してグラフ構造の列を構築する。具体的には、 t 番目のスナップショットにおけるエッジの重み a_{ijt} を、重み付き隣接行列 A の要素として定義する。これは、ノード v_i と v_j 間の正規化相互相関の絶対値として計算される。

情報の冗長性を防ぎ、疎なグラフを作成するために、隣接ノード間の相関をランク付けし、上位 τ 個の相関を持つエッジのみを保持する。すなわち、 v_j が v_i の隣接ノード集合に含まれる場合、 a_{ijt} は x_{it} と x_{jt} の正規化相互相関の絶対値として定義され、それ以外の場合は 0 とする。ここで、 x_{it} と x_{jt} は、 t 番目の脳波スナップショットにおける v_i チャンネルと v_j チャンネルを表す。また、隣接ノード集合は、相関値が高い上位 τ 個の隣接ノードの集合を表す。

この計算を T 個のスナップショットに対して行うことで、異なる時点における脳ネットワークを表す有向重み付き脳波グラフ G が得られる。言い換えると、脳波の動的性質は、これらのグラフ構造が時間経過に伴って変化する様子として捉えられる。

2.3 動的グラフニューラルネットワーク

本研究では、新たな TTG モデルを提案する。このモデルでは、GRU がノード特徴量を学習した後、グラフ畳み込みネットワーク、すなわち

GCN を用いて、静的グラフ上の電極間における空間的依存性を捉える。この手法は、発作の検出のために、脳波データに内在する時空間的ダイナミクスを効果的に捉える。

モデルの入力には、脳波信号そのものではなく、その周波数表現を用いる。ここでは、特定の周波数振動やスパイクなどの波形を特定することを目的とする。先行研究に従い、脳波信号に短時間フーリエ変換、すなわち STFT を適用し、非負の周波数成分の対数振幅を保持する。その後、データセット全体で正規化を行う。時間スナップショットの列からなる脳波周波数表現は、 $N \times T \times d$ のテンソル X として定式化され、 N 個のノードの初期化と動的グラフ構築に用いられる。

ノードとエッジの特徴の時間的ダイナミクスを捉えるため、それぞれを別のプロセスとして扱う 2 ストリーム Mamba フレームワークを導入する。動的脳波グラフ G に対し、Mamba は選択的な状態更新が可能な線形 RNN と解釈できるため、短期記憶と長期記憶の両方のプロセスを含む脳のダイナミクスのモデリングに適している。

脳において、短期記憶は短い間隔で一時的な情報を保持する。一方で、長期記憶は長い時間スケールにわたって過去の経験を現在の処理へ統合することを可能にする。系列 x_t を処理する従来の RNN において、隠れ状態の更新は、前時刻の隠れ状態 h_{t-1} と現在の入力 x_t に基づいて計算される。ここで、ニューロン間のシナプス接続性を表す重み行列 W と U は、時間 t を通じて固定されている。しかし、実際のシナプスの重みは常に変化し続けており、神経調整物質などの化学物質によって制御されている。これにより、固定された重みを用いる従来の RNN では、長い系列にわたって時間変化する情報を柔軟にモデル化する能力が制限される。対照的に、Mamba は各要素、すなわちノード特徴量や重み付き隣接行列に対して、入力依存のパラメータを持つ線形 RNN と見なすことができる。隠れ状

態は時間変化する神経活動を符号化し、一時的な作業記憶と、より持続的な長期記憶追跡の両方の基盤として機能する。

ソフトプラス活性化関数は、ゲート変数が正の値を保持することを保証し、それによって過去の神経状態を保持することと新たな入力を取り込むことの間のトレードオフを調整する。具体的には、忘却項は古くて役に立たない情報や無関係な情報を減衰させるシナプス減衰や抑制プロセスに類似した選択的処理を実行する。逆に、更新項は顕著な新しい情報を選択的に強化し、統合する神経調節性ゲートを反映している。

脳波信号における空間的依存性を効率的にモデリングするために、グラフ畳み込みネットワーク、すなわち GCN と、ラプラシアン位置符号化、を用いる。神経科学分野の研究により、特定の機能は新皮質やブローカ野などの特定の脳領域と密接に関係していることが明らかになっている。しかし、GNN の基本的な計算機構により、グラフ自己同型の下で構造的に等価なノードは同一の表現となり、実質的に個々の独自性を失うことになる。

空間モデリングにおいて脳の空間特性を反映するため、ラプラシアン位置符号化を導入する。エッジ特徴量に対して、正規化ラプラシアン L を定義する。正規化ラプラシアン L に対して固有値分解を行うことで、固有ベクトル行列 U と固有値を含む対角行列 Λ が得られる。ネットワークのグローバルな幾何構造を捉えるため、最小の固有値に対応する最初の K 個の固有ベクトルを選択する。ノード i について、そのラプラシアンベースの位置符号化 $\mathbf{p}_i$ は、これらの固有ベクトルにおけるノード i の成分を並べたベクトルとして与えられる。その後、ノードの時間特徴と位置符号化 $\mathbf{p}_i$ を連結し、ノード特徴として用いる。空間依存性を学習するために GCN を適用する。これらのグラフ埋め込みは、脳波スナップショットの時間変化を捉え、各スナップショットはその特定の時間における脳の

状態を反映している。GCN の各層は、隣接ノードとエッジから情報を集約することでノード埋め込みを更新する。

その後、発作検出タスクのために、最終層のノード埋め込み Z に対して Max Pooling を適用し、さらに全結合層とソフトマックス活性化関数を適用する。

3. 実験評価

3.1 タスク設定

本研究では、発作検出タスクに焦点を当てる。発作検出は、脳波データの特定区間が発作状態か非発作状態かを判別する 2 値分類問題として定式化される。本タスクは、自動発作モニタリングシステムの基盤となる重要な課題である。

3.2 データセット

手法の評価には、Temple University Hospital EEG Seizure dataset v1.5.2、すなわち TUSZ を用いた。TUSZ は公開されている脳波発作データベースの中で最大規模であり、5,612 件の脳波記録と、アノテーション付きの 3,050 件の発作イベントを含む。各記録は 19 チャネルの脳波から構成されている。TUSZ に対しては、公式に提供されているデータ分割に従い、特定の患者群をテスト用として使用した。

3.3 比較手法

比較手法として、4 つの動的 GNN 手法を選択した。具体的には、EvolveGCN-O、DCRNN、GRAPHS4MER および GRU-GCN を含めた。さらに、脳波向け基盤モデルとして、BIOT、LaBraM、EEGPT を評価に含めた。LaBraM および EEGPT については、公開されているベースモデルのチェックポイントからファインチューニングを行った。加えて、LSTM、CNN-LSTM、ならびに従来手法としてサポートベクターマシン、すなわち SVM と、ランダムフォレストも評価対象とした。

3.4 評価指標

評価指標として、Receiver Operating Characteristic 曲線下面積、すなわち AUROC と、F1 スコアを用いた。AUROC は、さまざまな閾値設定における性能を考慮し、クラス識別能力を包括的に評価する指標である。一方、F1 スコアは、適合率、すなわち precision と、再現率、すなわち recall のバランスを考慮した最適な閾値での性能に焦点を当てる。すべての結果は、異なる乱数シードを用いた 5 回の実行の平均として報告する。

3.5 実験結果

表 1: 発作検出の比較実験結果

Methods	Detection			
	12s		60s	
	AUROC	F1	AUROC	F1
SVM	0.765 ± 0.004	0.369 ± 0.007	0.720 ± 0.017	0.390 ± 0.019
Random Forest	0.778 ± 0.004	0.354 ± 0.005	0.739 ± 0.031	0.386 ± 0.038
LSTM	0.794 ± 0.006	0.381 ± 0.019	0.720 ± 0.014	0.392 ± 0.012
CNN-LSTM	0.754 ± 0.009	0.356 ± 0.008	0.680 ± 0.007	0.331 ± 0.016
BIOT	0.726 ± 0.016	0.320 ± 0.018	0.651 ± 0.024	0.280 ± 0.013
LaBraM	0.825 ± 0.003	0.472 ± 0.013	0.793 ± 0.002	0.469 ± 0.010
EEGPT	0.803 ± 0.005	0.415 ± 0.011	0.743 ± 0.003	0.406 ± 0.012
EvolveGCN	0.757 ± 0.004	0.343 ± 0.012	0.670 ± 0.017	0.340 ± 0.015
DCRNN	0.817 ± 0.008	0.415 ± 0.039	0.808 ± 0.014	0.435 ± 0.019
GRAPHS4MER	0.833 ± 0.005	0.413 ± 0.017	0.778 ± 0.021	0.439 ± 0.012
GRU-GCN	0.856 ± 0.009	0.505 ± 0.009	0.822 ± 0.013	0.438 ± 0.014
EvoBrain(Ours)	0.877 ± 0.005	0.539 ± 0.009	0.865 ± 0.009	0.483 ± 0.006

表 1 は、TUSZ データセットにおける発作検出タスクについて、12 秒および 60 秒のウィンドウ長を用いた各種モデルの性能比較を示している。提案手法は、すべての動的 GNN 比較手法を一貫して上回る性能を示し、大規模基盤モデルである LaBraM と比較してもパラメータ数が約 30 分の 1 でありながら、競争的な性能を達成している。12 秒ウィンドウの発作検出タスクにおいて、method は LaBraM と比較して AUROC を 14%、F1 スコアを 12%向上させた。また、60 秒ウィンドウのデータでは、EvolveGCN と比較して AUROC を 23%、F1 スコアを 30%、すなわち 0.340 から 0.483 へ向上させた。さらに、すべての TTG 系モデルが相対的に高い性能を示している。

4. おわりに

本研究では、動的マルチチャネル脳波グラフモデリング手法である EvoBrain を提案した。動的グラフモデリングを組み合わせることで、EvoBrain は脳ネットワークの進化的な性質を効果的に捉える。EvoBrain は、既存の動的 GNN モデルに対して AUROC で 23%、F1 スコアで 30%の性能向上を達成し、発作検出タスクにおいて高い性能を示した。以上の結果から、本研究は、信頼性が高く臨床的に意味のある脳波解析に向けた、実用的かつ理論的に裏付けられた新たな枠組みを提示する。

参考文献

- (1) Burns, S. P. et al., Network dynamics of the brain and influence of the epileptic seizure onset zone, Proceedings of the National Academy of Sciences, pp. E5321--E5330 (2014).
- (2) Li, A. et al., Neural fragility as an EEG marker of the seizure onset zone, Nature Neuroscience, pp. 1--10 (2021).
- (3) Cai, D. et al., MBrain: A Multi-Channel Self-Supervised Learning Framework for Brain Signals, Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, pp. 130--141 (2023).
- (4) Ho, T. K. K. et al., Self-Supervised Learning for Anomalous Channel Detection in EEG Graphs: Application to Seizure Analysis, Proceedings of the AAAI Conference on Artificial Intelligence, pp. 7866--7874 (2023).
- (5) Tang, S. et al., Self-Supervised Graph Neural Networks for Improved Electroencephalographic Seizure Analysis, International Conference on Learning Representations (2022).
- (6) Gu, A. et al., Mamba: Linear-Time Sequence Modeling with Selective State Spaces, arXiv preprint arXiv:2312.00752 (2024).