



ネットワークから知識を見出す

友人関係や交通網などのネットワーク(グラフ)構造に注目して、情報や病気の伝搬の解明・制御、将来の構造予測、またグラフを対象とした深層学習であるグラフニューラルネットワーク(GNN)などの研究をしています。

欠損値を含むグラフを扱うGNN

欠損した特徴の入力とグラフ学習を同じニューラルネットワークアーキテクチャ内に統合しました。欠損データをガウス混合モデル(GMM)で表現し、GCNの第一隠れ層のニューロンの期待活性化を計算し、従来の手法よりも高性能で頑強になりました。


Hibiki Taguchi, Xin Liu, Tsuyoshi Murata, "Graph Convolutional Networks for Graphs Containing Missing Features", Future Generation Computer Systems, Vol.117, pp.155-168, Elsevier, 2021.

<https://doi.org/10.1016/j.future.2020.11.016>



Our Approach

Integrates processing of missing features and graph learning within the same architecture




欠損が非常に多くても高精度なGNN

実世界のグラフにおいては、センシティブな情報などで、大部分のノード特徴量が欠落している場合がしばしばあります。そのような状況でグラフニューラルネットワークを直接適用すると、ノード分類などのタスクにおいて最適な性能が得られないことがあります。そこで本研究では、古典的なラベル伝播(Label Propagation: LP)の潜在能力を改めて引き出す新たなフレームワークを提案しています。特に、特徴量が部分的にしか利用できない状況において、特徴伝播(Feature Propagation: FP)を活用する点に着目します。本手法はGOODIEと名付けられ、ラベル伝播分岐と特徴伝播分岐の両方から埋め込みを取得するハイブリッドなアプローチを採用しています。広範な実験の結果、提案手法のGOODIEは、特徴量が少ない場合だけでなく、特徴量が豊富な場合においても、既存の最先端手法を上回る性能を示すことを確認しました。

Sukwon Yun, Xin Liu, Yunhak Oh, Junseok Lee, Tianlong Chen, Tsuyoshi Murata, Chanyoung Park, "Oldie but Goodie: Re-illuminating Label Propagation on Graphs with Partially Observed Features", Proceedings of the 31st ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD 2025), pp.3704-3715, 2025.

<https://doi.org/10.1145/3711896.3737067>

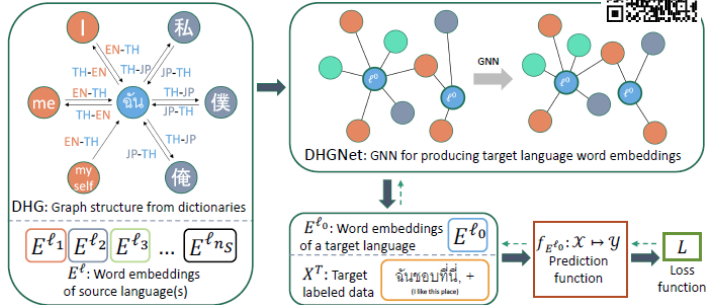


言語横断テキスト分類(CLTC)

資源が豊富な言語の訓練データを使って、資源が乏しい言語の分類問題を解くための転移学習では、資源が豊富な言語のタスク固有の訓練データは入手困難です。代替案として、資源が豊富な言語のタスクに依存しない単語埋め込みと、2言語間の辞書を用いたCLTCを提案しました。2言語間の辞書から異種頂点グラフを作り、単語レベルと言語レベルの2段階集約を行う高性能のグラフニューラルネットワークを構築した結果、大規模コーパスを利用しないのに事前学習モデルよりも高性能を実現しました。

Nuttapong Chairatanakul, Noppayut Sriwatanasakdi, Nontawat Charoenphakdee, Xin Liu, Tsuyoshi Murata, "Cross-lingual Transfer for Text Classification with Dictionary-based Heterogeneous Graph", Findings of the Association for Computational Linguistics: EMNLP 2021, pp.1504-1517, 2021.

<https://doi.org/10.18653/v1/2021.findings-emnlp.130>

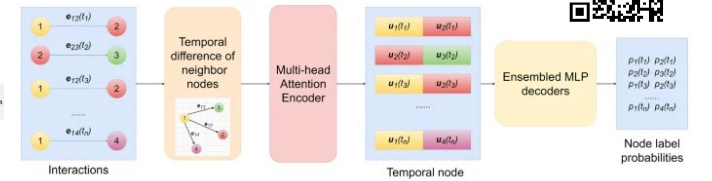


YouTubeの投げ銭を予測するGNN

近年、YouTube Live や Twitch といったオンラインのライブ配信プラットフォームは急速に人気を高めています。これらのライブ配信プラットフォームにおける寄付(投げ銭)についての研究はこれまでほとんど行われていませんでした。本研究はリアルタイムのチャットメッセージに基づいて視聴者間の相互作用をモデル化する連続時間動的グラフを構築し、ライブ配信プラットフォームにおけるリアルタイムの寄付を予測する手法を提案します。ライブ配信中の潜在的な寄付者を特定する新しいモデルであるTemporal Difference Graph Neural Network (TDGNN)を提案しています。このモデルは、寄付が発生する正確な時刻を予測することが可能です。3つのライブ配信動画データセットを用いた実験で、提案手法が他分野のベースライン手法と比較して、より高い有効性と頑強性を有することを示しました。

Jin Ruidong, Xin Liu, Tsuyoshi Murata, "Predicting Potential Real-time Donations in YouTube Live Streaming Services via Continuous-time Dynamic Graph", Machine Learning, Vol.113, pp.2093-2127, 2024.

<https://doi.org/10.1007/s10994-023-06449-z>

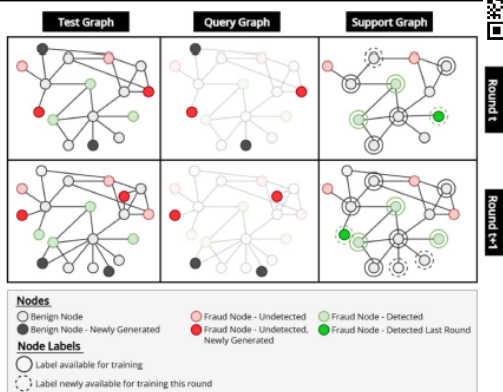


GNNによる不正検知

金融機関や金融活動のデジタル化が進む中で、不正検知のための信頼性の高いモデルの開発はますます重要になっています。本研究では、グラフ不正検知の新たなシナリオとして“Multi-round Adversarial Fraud Detection”を提案しています。このシナリオでは、不正検知モデルは敵対的に進化するグラフ上で反復的に学習および評価されます。さらに性能を改善するために、自己教師あり事前学習を活用し、複数ラウンドにわたる時間的情報を明示的に分離・強化するモジュールである“Temporally Pre-trained Node Embedder (TPNE)”を提案して、性能を改善しています。

Hafizh Adi Prasetya, Xin Liu, Tsuyoshi Murata, Akiyoshi Matono, “A Multi-rounded Adversarial Scenario for Graph-based Promo Fraud Detection”, Social Network Analysis and Mining, Vol.16, No.24, pp.1-30, 2026.

<https://doi.org/10.1007/s13278-025-01566-0>




GNNによる中心性の近似計算

SNSや交通網、Webなど、グラフは数多くの場面で用いられます。グラフ中のどのノードが重要であるかを特定することは、グラフにおける重要な問題の一つです。本研究では、グラフニューラルネットワーク(GNN)を用いて、中心性を近似計算するモデルを初めて提案しました。GNNでは、各ノードが近傍のノードの特徴を集約するので、この特徴集約スキームを用いて経路をモデル化し、特定のノードに到達可能なノードの数を学習します。人工データおよび実世界のデータに対する広範な実験を通して、我々のアプローチがより少ない時間で、現在の技術を著しく上回ることを実証しています。コードは以下のサイトに公開しています。

https://github.com/sunilkmaurya/GNN_Ranking

Sunil Kumar Maurya, Xin Liu, Tsuyoshi Murata, “Graph Neural Networks for Fast Node Ranking Approximation”, ACM Transactions on Knowledge Discovery from Data, Vol.15, No.5, Article No.78, 32 pages, 2021.

<https://doi.org/10.1145/3446217>






深層学習における継続学習

一度学習した後に認識対象のクラスが追加されるclass-incremental learning (CIL)において、深層学習は古いクラスに対する性能が極端に低下する破滅的忘却の影響を受けることが知られています。さらにexemplar-freeなCILは、過去データを一切保存せずに、新しいクラスを順次学習していくという非常に困難な設定です。本研究では、テキストから画像を生成する事前学習済みの拡散モデルを用いて、将来出現するクラスの合成画像を生成し、それらを用いて特徴抽出器を学習する手法を提案しています。標準ベンチマークであるCIFAR100およびImageNet-Subsetによる実験により、提案手法がexemplar-freeなCILにおける既存の最先端手法を改善できることを示しています。特に、最初の増分ステップに含まれるクラス数が少ないという最も困難な設定において有効です。

Quentin Jodelet, Xin Liu, Yin Jun Phua, Tsuyoshi Murata, “Future-proofing class-incremental learning”, Machine Vision and Applications, Vol.36, No.16, pp.1-16, 2025.

<https://doi.org/10.1007/s00138-024-01635-y>



「Pythonで学ぶネットワーク分析 — ColaboratoryとNetworkXを使った実践入門」村田剛志, オーム社 (2019)

<https://www.ohmsha.co.jp/book/9784274224256/>



「グラフニューラルネットワーク — PyTorchによる実装」村田剛志, オーム社 (2022)

<https://www.ohmsha.co.jp/book/9784274228872/>



村田剛志研究室
大岡山キャンパス西8号館E棟5階

<https://www.net.comp.isct.ac.jp/>

