

道路ネットワーク上の施設配置傾向把握に向けたマルチスケール注意機構 Multi-Scale Attention Mechanism for Grasping Facility Location Trends on Road Networks

織田 悠雅[†]
Yuma Oda

伏見 卓恭[†]
Takayasu Fushimi

1. はじめに

現代の都市計画や商業戦略において、施設の立地傾向を把握することは重要な課題である。特に、コンビニエンスストア（以下、コンビニ）のような日常的に利用される施設は、人々の生活動線や地域特性と密接に関連しており、その配置には地理的・社会的要因が複雑に絡んでいる。従来、施設の立地分析は空間統計や回帰分析により行われてきたが、これらの手法は空間的依存関係やネットワーク構造を十分に考慮することが難しいという限界があった [1]。

一方で、近年のグラフニューラルネットワーク (Graph Neural Networks: GNN) の発展により、道路ネットワークのような複雑な構造を持つデータに対して、ノード間の関係性を活用した高精度な予測や表現学習が可能になってきている [2]。中でも、GAT (Graph Attention Networks) [3] は、隣接ノード間の重要度に応じた情報伝播を行うことができ、交通網や施設配置のような空間ネットワークにおいて有効性が示されている。

本研究では、各交差点ノードに対して近隣の施設ジャンル（例：ガソリンスタンド、飲食店、学校等）の有無を多次元ベクトルとして付与し、特定の施設（本研究ではコンビニ）の立地傾向を予測する問題に取り組む。提案手法の特徴は、従来の隣接ノードによる畳み込みに加え、各ノードから近距離・中距離・遠距離ノードへランダムに擬似的なエッジを追加する点にある。これにより、地理的に離れた場所との関係性も考慮した表現が可能となる。すなわち、距離スケールごとの情報を動的に統合できる GAT ベースの施設配置予測モデルを構築し、コンビニの立地傾向を予測可能にすることを目的とする。さらに、モデルの注意重みや入力勾配を分析することで、他の施設ジャンルがコンビニの立地に与える影響を可視化し、立地戦略や都市分析に貢献することを目指す。

2. 提案手法

本研究では、道路ネットワーク上における特定施設（例：コンビニ）の立地傾向を把握するために、マルチスケール注意機構を備えたグラフアテンションネットワーク (GAT) モデルを提案する。本節では、まず対象問題を定式化し、次にマルチスケール GAT アーキテクチャ、および学習方法について述べる。

2.1. 問題設定

道路ネットワークを無向グラフ $G = (\mathcal{V}, \mathcal{E})$ とし、各ノード $v_i \in \mathcal{V}$ は交差点や道路分岐点などに対応する。ノードには、周辺に存在する施設ジャンル（例：飲食店、スーパー、ガソリンスタンドなど）の有無に関するマルチラベルベクトル $\mathbf{x}_i \in \{0, 1\}^D$ が与えられており、各次元は施設ジャンルごとの有無を表す。対象は、これらの情報をもとに、各ノードにおける特定の施設（例：コンビニ）の存在確率 $y_i \in \{0, 1\}$ を推定する分類問題である。

2.2. マルチスケール GAT アーキテクチャ

道路ネットワークのような空間グラフでは、ノード周辺の構造には近距離 (near)、中距離 (mid)、遠距離 (far) の異なるスケールの影響が存在する。そこで本研究では、ノード v_i に対してマルチスケール擬似エッジを導入する。それぞれのスケール $s \in \mathcal{S} = \{\text{near}, \text{mid}, \text{far}\}$ の下限と上限を $\text{lower}_s, \text{upper}_s$ とし、ノード v_i から見てスケール s のノード集合を $\mathcal{V}^{(s)}(i) = \{v_j \in \mathcal{V}; \text{lower}_s \leq \text{euclid}(v_i, v_j) < \text{upper}_s\}$ とする。各スケールで、施設ベクトル \mathbf{x} 間のコサイン類似度 $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$ に基づく確率にしたがってランダムに k 個のノード $\Gamma^{(s)}(i) \subseteq \mathcal{V}^{(s)}(i)$ を選び、擬似的にエッジとして追加する： $\mathcal{E}^{(s)} = \{\{v_i, v_j\}; v_j \in \Gamma^{(s)}(i), i \in \mathcal{V}\}$ 。

このように構築したマルチスケールの隣接構造ともとの道路構造を統合する：

$$\mathcal{E}^{(S)} \leftarrow \bigcup_{s \in \mathcal{S}} \mathcal{E}^{(s)} \cup \mathcal{E}$$

これをメタグラフ $MG = (\mathcal{V}, \mathcal{E}^{(S)})$ と呼ぶ。メタグラフ MG に対して、GAT を適用し、隠れ層のベクトルを得る：

$$\mathbf{h}_i^{(S)} = \text{GAT}^{(S)}(\mathbf{x}_i, \Gamma^{(S)}(i)).$$

ここで、 $\Gamma^{(S)}(i)$ は MG 上でのノード i の隣接ノード集合である。この表現を用いて、最終的に MLP によって対象施設の存在確率を出力する：

$$\hat{y}_i = \sigma(\text{MLP}(\mathbf{h}_i)).$$

[†]東京工科大学コンピュータサイエンス学部

表 1: 予測精度

	(a) 横浜			提案手法	(b) 八王子			提案手法
	比較手法 (GAT)				比較手法 (GAT)			
	0層	1層	2層		0層	1層	2層	
Loss ↓	0.941	0.637	0.499	0.461	1.232	0.585	0.470	0.446
Accuracy ↑	0.740	0.620	0.795	0.831	0.674	0.698	0.802	0.884
Precision ↑	0.763	0.781	0.794	0.883	0.653	0.815	0.842	0.867
Recall ↑	0.695	0.333	0.797	0.764	0.744	0.512	0.744	0.907

表 2: グラフの基本統計量

名前	八王子市	横浜市
ノード数 N	17,192	90,753
エッジ数 $ \mathcal{E} $	47,022	246,752
平均次数	5.47	5.44
平均ノード間グラフ距離	58.96	70.17
直径 (グラフ距離)	160	182
平均ノード間実距離 [m]	6,568.89	12,786.06
直径 (実距離) [m]	31,985.27	40,479.35

3. 評価実験

3.1. 実験設定

OpenStreetMap[‡]から、八王子市と横浜市の道路データと建物データを読み込み使用する。表 2 は、八王子市と横浜市の道路ネットワークの基本統計量である。

予測対象の施設 (今回はコンビニ) は、道路ネットワーク全体のノードに対して少数しか存在しないため、データは極めて不均衡である。この問題に対処するため、1 エポックごとにコンビニが存在しないノード (負例) からランダムに同数のノードを選択し、正例とバランスを取る負例のダウンサンプリングを実施した。

損失関数をクロスエントロピー損失、最適化法を Adam とした。

比較手法として、道路構造 $G = (\mathcal{V}, \mathcal{E})$ に対する 0 層, 1 層, 2 層のアテンション層を持つ GAT モデルを採用した。

評価には、クロスエントロピー損失 (Loss) と精度 (Accuracy), 適合率 (Precision), 再現率 (Recall) を用いた。

3.2. 実験結果

表 1 に比較手法と提案手法による予測精度を示す。横浜における実験結果では、GAT の層数が増加するにつれて Loss は低下し、2 層モデルで最も低い 0.499 を記録した。一方、提案手法ではそれをさらに下回る 0.461 を達成し、最も高い精度を示した。Accuracy においても、GAT 2 層モデルの 0.795 を上回る 0.831 を記録し、Precision は 0.883, Recall は 0.764 という指標においても GAT よりも高い数値を出した。特に、Precision の向上が顕著であり、GAT 1 層および 2 層モデルの性能を大きく上

回っている。八王子データに対しても、ほぼ同様の傾向が見られた。

4. おわりに

本研究では、GAT に基づく施設カテゴリ予測モデルに対し、マルチスケールな地理的文脈情報を統合する提案手法を導入し、横浜および八王子のデータセットにおいてその有効性を検証した。提案手法は、比較手法と比べていずれの指標においても高い精度を達成し、特に Precision および Recall の向上が顕著であった。これにより、従来の単一スケール GAT では捉えきれなかった広域的・局所的な文脈が、施設カテゴリ分類において重要な役割を果たすことが示唆された。

一方で、本手法は対象エリアに依存する構造情報やスケール設計に頑健でない可能性も残されており、より自動化されたスケール最適化や他地域への汎化性の検証が今後の課題である。将来的には、リアルタイムの都市解析や需要予測など、より実応用に近いタスクへの展開も視野に入れて研究を進めたい。

参考文献

- [1] Fushimi, T., Saito, K., Ohara, K., Kimura, M. and Motoda, H.: General framework of opening and closing shops over a spatial network based on stochastic utility under competitive and time-bounded environment, *Social Network Analysis*, Vol. 11, No. 70 (2021).
- [2] Yu, B., Yin, H. and Zhu, Z.: Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting, *Proceedings of the 27th International Joint Conference on Artificial Intelligence, IJCAI'18*, AAAI Press, pp. 3634–3640 (2018).
- [3] Veličković, P., Cucurull, G., Casanova, A., Romero, A., Liò, P. and Bengio, Y.: Graph Attention Networks, *International Conference on Learning Representations* (2018).

[‡]<https://www.openstreetmap.org>