

グラフニューラルネットワークを用いた未観測地点の交通状況推定手法

田中 悠[†] 笠松 大佑[†]

[†] 創価大学大学院理工学研究科 〒192-8577 東京都八王子市丹木町 1-236

E-mail: [†]e25d5302@soka-u.jp, ^{††}dxk@ieee.org

あらまし 交通状況データの計測は地点が限られており、全ての地点で交通状況を把握することは難しい。既存の交通状況予測は完全教師あり学習が主流であり、未計測地点の混在を想定していない。本研究では未計測地点と計測地点が混在する場合に着目し、計測地点の交通状況から計測地点と未計測地点の交通状況を予測するモデルの構築に取り組む。学習手順に半教師あり回帰型を採用し、モデルに Graph Convolutional Network(GCN) に代表される構造的バイアスの獲得に特化した機構を組み込んだモデルを用いる。新宿駅周辺を対象に実験を行った結果、半教師あり回帰によって、過去数週間分の計測地点の交通状況から将来の未計測地点の交通量状況をベースラインより高い精度で予測することを確認した。

キーワード スマートシティ, 地理データ, 都市データ, グラフニューラルネットワーク, 交通

1 はじめに

交通分野における施策と交通状況調査の関係は強く、ビッグデータやディープラーニングを代表とする高度なデータ指向技術が発展する前の時代から、道路行政や交通計画の土台として利用されてきた [15], [16]。特に近年ではデータ指向技術の発展に伴い、都市部で観測されるあらゆる方面のデータを相互に利用することで各分野の機能を高度化する取り組みとして、アーバンコンピューティングの研究が進められている [13], [14]。交通分野においても、従来から利用されてきた都市間交通需要のような定常的でマクロな単位から見る交通状況だけでなく、交差点、車線合流部などの細かな地点ごとに、信号機の 1 サイクル時間の程の短さの、ミクロな単位で計測された交通状況データを活用していく事例が増えており [4], [8], [10]、応用の幅の広さから交通状況データはアーバンコンピューティングにおいて重要度を増している。

一方でミクロな交通状況をリアルタイムで計測し続けることは難しい。データを集める手段には、計測機器で構築された交通流計測システムにを用いて計測を行う方法と、個人の移動履歴から交通量を推定的に算出する HaaS (Human as a Sensor) の 2 つが存在するが [15]、いずれの手法にも網羅性の観点から制限がある。第一に交通流計測システムは設置と運用に要するコストの高さから広域を網羅的に観測することが難しい。日本で実運用されている警視庁の交通流計測システムにおいても、観測地点は都市部の一部のエリアや国道をはじめとする主要地点に限られている。また HaaS はモビリティ端末や交通車両に取り付けられた GPS(Global Positioning System) で計測した移動履歴を必要とするため、取得可能な団体は通信基盤を提供する事業者や、経路案内サービスを提供するサービスプロバイダなど一部の民間企業に限られる。

計測システムのハイコスト化問題はアーバンコンピューティングの文脈においても指摘されており [13]、対応策として完全




図 1 未計測地点を含む道路ネットワークにおける交通状況予測。

教師あり学習による補間手法 [7] が提案されている。しかしながら、完全教師あり学習による手法は既存のセンサーネットワークから不要な機器を減らすことによるコスト削減を目的としており、予測対象地点の計測データが存在することを前提とする。そのため既存システムの拡大には貢献しない。

そこで本研究では、計測地点と未計測地点が混在するネットワーク上において、グラフ構造を取り込む機構を持たせたディープラーニングモデルに半教師あり学習を適用し、回帰的に既存の計測データから過去データの存在しない未計測地点の交通量を推定する手法を設計することを目的とする (図 1)。

2 関連研究

GNN (グラフニューラルネットワーク). GNN (Graph Neural Network) はグラフ理論で発展したスペクトラル解析を応用したスペクトラル (Spectral GNN) 系、ノード間の結合に基づいて処理するスペーシャル (Spatial GNN) 系、注意機構を導入したアテンション (GAT: Graph Attention) 系の 3 つの系統を持つ。Spectral GNN はグラフ構造を行列として表現した隣接行列から算出されるグラフラプラシアン の性質を利用したモデルで、代表的なモデルにグラフ畳み込みニューラルネットワーク (GCN: Graph Convolutional Network) がある [6]。対して Spatial GNN はメッセージパッシングを基本とした方式であり、各ノードを隣接するノードの特徴量を用いて更新する。GAT は GCN の処理機構に注意機構を導入した処

理体系で、近接するノードや対象ノードの特徴量の値から動的に強く評価したいノードを選択し、対象ノードの値を更新する ([9], [3]).

ST-GCN(Spatio-Temporal Graph Convolutional Network) [12]. 時系列処理に特化したモジュールと GNN ブロックを組み合わせたモデルとして、ST-GCN(Spatio-Temporal Graph Convolutional Network) がある. ST-GCN では GNN ブロックとして採用された GCN と、時間系列ブロックとして 1 次元 CNN(Convolutional Neural Network) をベースにゲート機構を追加したゲート付き畳み込み層の 2 つが組み合わされて考案された、ST(Spatio-Temporal) ブロックが用いられており、モデル全体は ST ブロック 2 層と出力層で構成された. 過去の交通量データから未来の交通量データを予測する完全教師ありの課題において、予測精度の改善に成功している [12].

2.1 半教師あり学習

半教師あり学習は教師データが限られている状況で、モデルの最適化を行う際に適用される学習アルゴリズムである [11]. 教師あり学習と異なり、入力と出力の組に偏りなどがあり、一部の出力について正解データを用意できない場合に適用される. GNN はノードとノードの関係性から特徴量を更新するラベルプロパゲーション機構を持つことから、データの欠損を前提とした半教師あり学習による予測と高い親和性を持つことが指摘されている. 実際に GCN を用いて実施された半教師あり学習によるラベル予測において、その効果が確認された [6].

3 研究課題

複数のセンサーで構築された交通流量計測システムのオープンデータを用いて、計測地点と未計測地点の混在する道路ネットワークを想定し、それらの地点の未来の交通量を予測することを課題とする. 学習手順として半教師あり回帰の手順を採用し、モデルに道路ネットワークがもつ構造的な特性を取り込む機構と、計測地点と未計測地点でパラメータを共有する層を導入することで、教師データのない地点における交通状況予測の実現を試みる.

警察庁が運営する交通流量計測システムのオープンデータを利用して特性の異なるモデルを半教師あり回帰の手順で学習し、短期予測と長期予測の 2 つの検証シナリオで精度比較を通して、モデルの構造と学習手順が予測精度に与える影響を検証する.

4 提案手法

単位時間ごとに推移する交通状況特徴量 f_t について、事前に特徴量 f_t を取得できる計測地点 $v \in V_{source}$ と、取得できない未計測地点 $v \in V_{target}$ で構成される頂点集合 $V = V_{source} \cup V_{target}$ が道路ネットワーク構造に基づいて設定された接続関係 E によってグラフ $G = \{V, E\}$ を形成したとする. 入力単位時間ステップ数 t_{in} 個の計測地点の連続する特徴量 $f_{v \in V_{source}, t-t_{in}:t}$ から、続く目的単位時間ステップ数 t_{out} 個の全ての頂点の特徴量 $f_{v \in V, t+1:t+t_{out}}$ を予測するモデルを構築する.

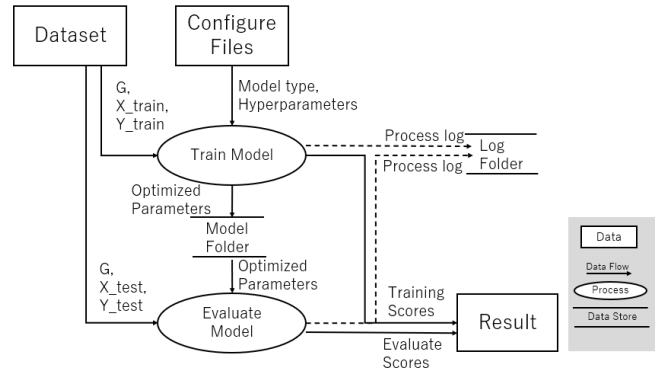


図 2 システム構成図.

4.1 システム構成と学習手順

グラフ G , 学習用の特徴量データ X_{train} と対応する正解データ Y_{train} , 検証用の特徴量データ X_{test} と対応する正解データ Y_{test} が存在するとき、モデル M を訓練し、精度を検証するシステムの全体像を図 2 に示す. 学習フェーズでは X_{train}, Y_{train}, G を用いて、予測モデルの半教師あり回帰学習を行う. このとき X_{train} のうち V_{target} に属する頂点に関する特徴量 $X_{train, target}$ の値はダミー値で代替する. また勾配計算に用いる損失関数 $\mathcal{L}(y, \bar{y})$ に渡す値は、 V_{source} に属する頂点に関する特徴量 $y_{source}, \bar{y}_{source}$ に限定する (式 1).

$$\text{TrainingLoss} = \mathcal{L}(y_{source}, \bar{y}_{source}). \quad (1)$$

検証フェーズでは X_{train}, Y_{train}, G を X_{test}, Y_{test}, G に置き換えて、頂点を限定せずに損失を算出する.

4.2 埋め込み層 (Embedding Layer)

未計測地点におけるパラメータ更新を促すため、入力層として未計測地点と計測地点でパラメータを共有する埋め込み層の導入を考案した. 埋め込み層の機構には 1 次元 CNN を採用する. 画像処理で用いられる 2 次元 CNN の場合、チャンネル方向の長さが C_{in} , 縦方向の長さが W , 横方向の長さが H である画像を処理するために、縦方向の長さが k_H , 横方向の長さが k_W , チャンネル方向の長さが C_{in} のカーネルを出力チャンネル数 C_{out} の数だけ持つ. このとき、入力チャンネルを交通状況特徴量 f , 縦方向を頂点 V , 横方向を時間 $t-t_{in}:t$ とみなし、カーネルサイズを頂点方向は 1, 時間方向は k_t , 出力チャンネル数は埋め込み後特徴量長に設定することで、共有カーネルを用いた埋め込みを実行することが可能となる. 特にストライド長とカーネルサイズ k_w を同じ大きさにすることで、時間方向の系列長を W/k_w に縮めることが可能である. 埋め込み層はカーネルサイズが異なる 2 層の 1 次元 CNN で構成する.

4.3 近傍平均モデル, GCN モデル, ST-GCN モデル

計測地点の特徴量データから計測地点, 未計測地点の特徴量を予測する予測モデルとして近傍平均モデル, GCN モデル, ST-GCN モデルを使用する. モデルアーキテクチャを図 3 に示す.

近傍平均モデル. グラフ構造を考慮した未計測地点の交通状況予測のベースラインとして近傍平均モデルを定義する. 入力




図3 モデルアーキテクチャ。(左)近傍平均モデル, (中央)GCN モデル, (右)ST-GCN モデル。

特徴量を時系列データとみなし, 計測地点ごとに異なる予測モデルを対応させ, 過去の交通状況から出力単位時間ステップ数 t_{out} 先までの該当地点の特徴量を予測するモデルを構築する。計測地点ごとの予測モデルは, 時系列データ処理に特化したモデルとして評価のある LSTM(Long Short Term Memory) [5] を採用する。なお出力層は全結合層とする。未計測地点の予測値には, 隣接する計測地点の予測値の平均値を採用する。

$$y_{source,i} = \text{Output}_i(\text{LSTM}_i(x_{source,i})) \quad (2)$$

$$y_{target,j} = \text{Average}(y_{i \in \text{Neighbor}(j) \cap V_{source}}). \quad (3)$$

GCN モデル. グラフ構造を考慮する学習可能ブロックとして, 中間層に 2 層の Graph Convolutional Network(GCN) [6] を採用した Sequence to Sequence 型の予測モデルを設計した。一度の推論で計測地点と未計測地点を含む全ての地点について出力単位時間ステップ数 t_{out} 先までの該当地点の特徴量を出力する。入力層には埋め込み層, 出力層には各頂点でパラメータを共有する全結合層を配置した。

ST-GCN モデル. グラフ構造に加えて時間方向の特性を考慮するブロックとして, 中間層に 2 層の Spatio-Temporal Graph Convolutional Network [12] を採用した予測モデルを設計した。入力層, 出力層には GCN モデルと同様に埋め込み層とパラメータを共有する全結合層を配置した。

5 実験

5.1 システム要件

実験システムとして, nvidia 製の汎用 GPU (RTX A5000) を搭載する ubuntu22.04 をインストールしたマシンに仮想空間を作成し, 仮想空間に Python, PyTorch, PyTorch Geometric を中心としたライブラリを導入した。搭載した GPU の RAM サイズは 24GB, CPU は 24 コア 100MHz, メインメモリのサイズは 32GB である。

5.2 実験条件

警察庁の交通流量計測システムのセンサーのうち新宿駅周辺の 85 地点を対象に, ランダムに抽出した 17 地点を未計測地点として実験を行う。交通状況特徴量は日本道路交通情報センターが公開する断面交通量を使用し [2], 接続関係は日本交通管



図4 新宿駅周辺の断面交通量観測地点。

理技術協会 [1] から取得した座標情報から手で設定する。対象エリアを図 4 に示す。断面交通量は 5 分ごとに計測される。2023 年 8 月から 2024 年 5 月までを学習データ, 2024 年 6 月から 7 月までを検証データとする。入力単位ステップ数は 14 日分に当たる $14 \times 24 \times 12$ とし, 出力単位ステップは 1 とする。断面交通量に含まれていた欠損値は, 1 時間を基準に欠損期間が短い場合は時間方向で線型補間を行い, 欠損期間が長い場合には同一時刻の平均値で補間した。

学習時, 検証時に用いる損失関数 \mathcal{L} は平均二乗誤差 (MSE:Mean Squared Error) とする。

検証はモデルが 1 回の推論出力するステップ数までの値を用いて評価する短期予測シナリオ評価と, 出力値を再帰的に入力し, 1 日程度先まで予測させて得た値を用いる長期予測シナリオ評価の 2 パターンで行う。評価スコアとして全体誤差 AllAreaLoss, 計測地点誤差 SourceLoss, 未計測地点誤差 TargetLoss の 3 つを算出する。評価誤差を以下に示す。式中の \parallel はテンソルの結合を意味する。

$$\text{AllAreaLoss} = \mathcal{L}(\bar{y}_{source} \parallel \bar{y}_{target}, y) \quad (4)$$

$$\text{SourceLoss} = \mathcal{L}(\bar{y}_{source}, y_{source}) \quad (5)$$

$$\text{TargetLoss} = \mathcal{L}(\bar{y}_{target}, y_{target}). \quad (6)$$

長期予測シナリオ評価では, 2024 年 6 月 1 日から 14 日までを第一の入力とし, 予測値のうち 1 ステップ分を前の入力の最後に追加して予測を再度実行する, という工程を繰り返すことで 1 日程度先までの予測値を出力する。予測長は 1 日分 (288) と数余剰ステップ 18 時間分 (216) で計 504 ステップとする。

使用するモデルは近傍平均モデル, GCN モデル, ST-GCN モデルの 3 種とする。学習率, エポック数, バッチサイズは 0.001, 5, 300 を基本とし, 近傍平均モデルのみ学習率を 0.005, エポック数を 15 に設定した。

また剪定実験として, 入力層を単純な全結合層に置き換えた GCN - Emb モデルを用意し, 埋め込み層によるパラメータ共有の効果を検証した。

5.3 実験結果

短期予測シナリオ, 長期予測シナリオにおけるモデルごとの

表 1 シナリオごとの各モデルの予測誤差 (MSE).

短期予測シナリオ	全体	計測地点	未計測地点
Neighbor Avg	280.912	197.835	613.220
GCN	550.269	443.778	976.233
ST-GCN	714.575	369.076	2096.573
GCN - Emb	525.277	448.783	831.254
長期予測シナリオ	全体	計測地点	未計測地点
Neighbor Avg	626.691	557.901	901.852
GCN	629.499	635.645	604.912
ST-GCN	602.733	304.451	1795.864
GCN - Emb	823.966	902.351	510.424




図 5 未計測地点 827 (宮下) における長期予測の結果.




図 6 計測地点 2259 (大久保二) における長期予測の結果.

予測精度を表 1 に示す. 評価指標は左から順に, 評価指標は全体誤差 AllAreaLoss, 計測地点誤差 SourceLoss, 未計測地点誤差 TargetLoss を指す.

5.4 短期予測シナリオにおける評価

評価指標を比較した結果, 全体, 計測地点, 未計測地点のすべての場合において近傍平均モデルの予測誤差が小さいという結果となった. 特に計測地点における精度が高く, 短期予測において過去データと正解値は強い結びつきを持つことが確認された. 一方で GCN モデルは, 予測誤差は近傍平均モデルよりも大きかったものの, 計測地点に対する未計測地点の精度比が 2.13 倍で, 精度比が 3 倍以上あった近傍平均モデルと比べて小さく, 計測地点と未計測地点での精度差が小さいことから, ノード間でのプロパゲーション機構が有意に働いたことを示す結果となった.

ST-GCN モデルは未計測地点における予測誤差が 2096 と最も大きく, 精度比は 5 倍あることから, 未計測地点における予測には向かない結果となった.

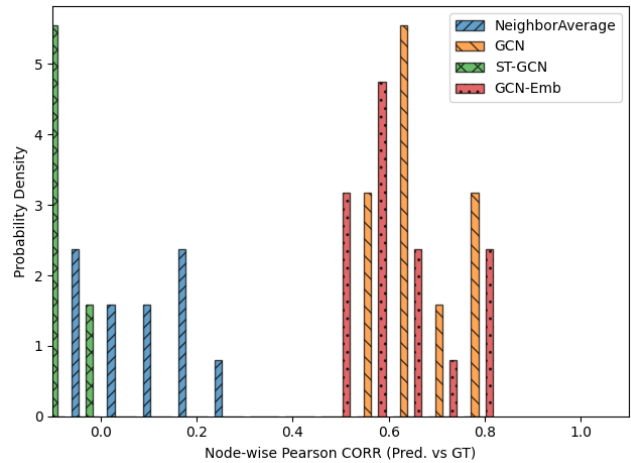


図 7 未計測地点における正解値と予測値の相関の強さ.




図 8 計測地点における正解値と予測値の相関の強さ.

5.5 長期予測シナリオにおける評価

再帰的な推論による長期間の予測を行った例として, 未計測地点 (宮下) と計測地点 (大久保二) における予測値の折れ線グラフを図 5, 6 に示す.

プロットの結果, GCN モデルのみ未計測地点と計測地点において長期間波形を再現することに成功した. 近傍平均モデルと ST-GCN モデルは 1 から 2 ステップ先までは予測可能であるものの, 以降は出力値が横ばいとなっており, 予測退化の発生を示す結果となった.

そこで予測退化の発生傾向を確認するため, 各モデルの出力と正解値との相関係数を算出した. 未計測地点, 計測地点においてモデルごとに各ノードの相関係数をヒストグラムとしてまとめた結果を図 7, 8 に示す. その結果, 近傍平均モデルと ST-GCN モデルにおいて相関係数が小さい傾向にあることが発覚した. 特に計測地点における相関係数の分布が低い値に寄っていることから, 未計測地点が持つノイズや半教師あり学習による影響ではなく, 採用したモデルの特性として予測退化が発生しやすい状態にあったと考えられる.

近傍平均モデルにおいて予測が退化した原因は, ベースとする LSTM が, 再帰的な予測を想定していないモデルであった可能性があげられる. 入力値のうち実測値の値が占める割合が

減ることで、入力ベクトル内に予測誤差を持つ値の割合が増加し、ベクトル内の値の分布が未知となった結果、モデルが安定解として定数を出力するようになったと考えられる。

また ST-GCN モデルにおいても同様に予測が退化したことから、ベースとする ST-GCN の時系列方向に対する分布の獲得度が高く、予測誤差による入力ベクトルの分布ずれに対応できなかつたと考えられる。

対して GCN モデルは、時系列予測特性を獲得する機能が構造的に弱いことが、結果として予測退化への耐性を持つこととなった。このことから、再帰推論によって長期予測を行う場合、時間方向での入力分布への依存度を小さくし、予測誤差による分布のずれに対応できるモデルを構築する必要がある。

5.6 剪定実験: 埋め込み層の評価

入力層として採用した埋め込み層を評価するため、GCN モデルと GCN-Emb モデルについて短期予測シナリオ・長期予測短期予測シナリオにおける予測誤差、長期予測のプロット、正解値と予測値の相関係数の強さの比較を行う。

短期予測シナリオにおける予測誤差を比較したところ、計測地点での精度が改善する一方で、未計測地点では予測精度が悪化することが確認された。未計測地点での予測精度は 140 ポイント近く悪化しており、計測地点での改善値と比べて大きいことから導入効果が小さく見える結果となった。一方で長期予測シナリオでは、未計測地点での精度悪化は 100 ポイント前後に収まっているにも関わらず、計測地点での精度改善は 200 ポイントを超えており、総じて計測地点での精度改善効果が高いといえる結果となった。

長期予測のプロットから、GCN モデルの予測値は GCN-Emb モデルの予測値と比較して小さくなる傾向があった。正解値に対して GCN モデルの値が高い値を予測している場合でも、GCN モデルが低い値を予測している場合でも、GCN-Emb モデルの予測値は GCN モデルの予測値よりも低い位置にあることから、埋め込み層の導入した結果、予測値が小さくなる方向にバイアスがかかるようになった可能性がある。

相関係数の分布からは大きな差分は読み取れず、予測退化の発生しやすさと埋め込み層の関係は小さいことが分かった。

6 まとめ

計測地点の情報から未計測地点の交通状況を予測する問題を定義し、半教師あり学習でモデルを学習する実験を行った。新宿駅周辺の 85 地点のうち 17 地点を未計測地点と仮定し、近傍平均モデル、GCN モデル、ST-GCN モデルについて、MSE を指標に精度を比較した。実験結果から数ステップ先は近傍平均モデルで、1 日分の予測であれば GCN モデルで予測可能であることが分かった。

また剪定実験の結果、入力層の時点で共有パラメータを持つことは、未計測地点の予測精度を悪化する傾向があるものの、計測地点における長期予測の安定に寄与する可能性が示された。

一方で近傍平均モデル、ST-GCN モデルにおいては予測誤

差が発生しており、時系列特性を獲得する機構と、再帰的推論におけるモデルの頑強性の間に強い関係があること、それは単純な平均事情誤差では評価しきれないことが示唆された。

今後の研究では、問題設定に即した精度指標の設定、パラメータ共有が精度差の改善に与える影響の調査、精度改善のための処理機構の作成が課題となる。

文 献

- [1] 断面交通量計測地点位置情報 (詳細版 b, 東京都), 公益財団法人日本交通管理技術協会. <https://www.tmt.or.jp/research/index9.html>.
- [2] 断面交通量情報, 公益財団法人日本道路交通情報センター. <https://www.jartic.or.jp/service/opendata/> (2023/11/4, 2023/12/6 2024/1/10 アクセス).
- [3] Shaked Brody, Uri Alon, and Eran Yahav. How attentive are graph attention networks?, 2022.
- [4] Austin Derrrow-Pinion, Jennifer She, David Wong, Oliver Lange, Todd Hester, Luis Perez, Marc Nunkesser, Seong-jae Lee, Xueying Guo, Brett Wiltshire, Peter W. Battaglia, Vishal Gupta, Ang Li, Zhongwen Xu, Alvaro Sanchez-Gonzalez, Yujia Li, and Petar Velickovic. Eta prediction with graph neural networks in google maps. In *Proceedings of the 30th ACM International Conference on Information & Knowledge Management, CIKM '21*, p. 3767–3776, New York, NY, USA, 2021. Association for Computing Machinery.
- [5] Sepp Hochreiter and Jürgen Schmidhuber. Long Short-Term Memory. *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780, 11 1997.
- [6] Thomas N. Kipf and Max Welling. Semi-Supervised Classification with Graph Convolutional Networks. *arXiv e-prints*, p. arXiv:1609.02907, September 2016.
- [7] Giuseppina De Luca and Mariano Gallo. The use of artificial neural networks for extending road traffic monitoring data spatially: an application to the neighbourhoods of benevento. *Transportation Research Procedia*, Vol. 45, pp. 635–642, 2020. Transport Infrastructure and systems in a changing world. Towards a more sustainable, reliable and smarter mobility. TIS Roma 2019 Conference Proceedings.
- [8] Ryu Shirakami, Toshiya Kitahara, Koh Takeuchi, and Hisashi Kashima. Qtnet: Theory-based queue length prediction for urban traffic. In *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, KDD '23*, p. 4832–4841, New York, NY, USA, 2023. Association for Computing Machinery.
- [9] Petar Veličković, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Liò, and Yoshua Bengio. Graph attention networks, 2018.
- [10] Yanan Xu, Yanmin Zhu, Yanyan Shen, and Jiadi Yu. Fine-grained air quality inference with remote sensing data and ubiquitous urban data. *ACM Trans. Knowl. Discov. Data*, Vol. 13, No. 5, pp. 1–27, sep 2019.
- [11] Xiangli Yang, Zixing Song, Irwin King, and Zenglin Xu. A survey on deep semi-supervised learning. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 35, No. 9, pp. 8934–8954, 2023.
- [12] Bing Yu, Haoteng Yin, and Zhanxing Zhu. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. In *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence, IJCAI-18*, pp. 3634–3640. International Joint Conferences on Artificial Intelligence Organization, 7 2018.
- [13] Yu Zheng, Licia Capra, Ouri Wolfson, and Hai Yang. Urban computing: Concepts, methodologies, and applications.

ACM Trans. Intell. Syst. Technol., Vol. 5, No. 3, pp. 1 – 55, sep 2014.

- [14] Xingchen Zou, Yibo Yan, Xixuan Hao, Yuehong Hu, Haomin Wen, Erdong Liu, Junbo Zhang, Yong Li, Tianrui Li, Yu Zheng, and Yuxuan Liang. Deep learning for cross-domain data fusion in urban computing: Taxonomy, advances, and outlook, 2024. arXiv:2402.19348.
- [15] 飯田恭敬. 交通工学. オーム社, 東京, 2008.
- [16] 国土交通省道路局. 道路行政の簡単解説, 2024. 国土交通省ウェブサイト.