

Gray-Level Co-occurrence Matrixを用いた 画像認識による高速道路の渋滞予測

神戸大学大学院 工学研究科 市民工学専攻
○D2 安田 昌平 M2 小倉 大輝
M2 佐々木 泰 M2 福嶋 一矢

今回試みたこと


高速道路の速度情報を時空間的に可視化
画像認識系の機械学習（パターン認識）手法を用いて、
予測したい日の交通状態と類似する候補画像を抽出
それらを合成することで**交通状態の予測画像を生成**した。

— 使用したインフラデータ —

- ・ 高速道路情報（NEXCO東日本，NEXCO中日本）
- ・ トラカンデータ（首都高速道路）
- ・ 商用車プローブデータ（富士通）
- ・ デジタル道路地図データ（日本デジタル道路地図協会）

交通状態の可視化（例）


富士通プローブデータで観測された速度情報の90パーセンタイル値を**自由流速度**として推定
各**DRM**リンクについて紐付けて可視化



交通状態の可視化（例）

15分毎の速度低下比率を計算して可視化
（前ページの推定自由流速度と比較）

2017/2/1 7:30~7:45



交通状態の可視化（例）

15分毎の速度低下比率を計算して可視化
（前ページの推定自由流速度と比較）


2017/2/1 7:45~8:00



交通状態の可視化（例）

15分毎の速度低下比率を計算して可視化
（前ページの推定自由流速度と比較）

2017/2/1 8:00~8:15



時空間的変動パターンの学習

広範囲の交通状態を観測するデータや精度高いネットワークデータが得られるようになり、可視化が非常に楽に

交通状態の時空間的な変動を直感的に認識可能

→画像的にパターンを学習し、予測に繋がらないか


画像認識系の機械学習アルゴリズムを用いて、
交通流理論等とは異なる観点から、将来の交通状態予測を行ってみる

分析手法・アルゴリズム

画像認識のアルゴリズム


Gray-level Co-occurrence Matrix(GLCM)¹⁾を用いた類似度の測定

通常画像は各セルの値が個別のデータとなるため、データの次元が膨大になりがちであるが、隣接セルとの値の変動を一つの行列にまとめたGLCMに変換（特徴量の抽出）を行うことにより類似度を簡便に計算。




GLCMを用いた旅行時間予測の既存研究²⁾

Zhang et. al. (2017)は、過去の膨大なtime-space diagramをGLCMに変換し、パターン認識による将来の旅行時間予測を行った。



GLCMを用いた旅行時間予測の既存研究²⁾


Zhang et. al. (2017)は、過去の膨大なtime-space diagramをGLCMに変換し、パターン認識による将来の旅行時間予測を行った。



- Gray levelを設ける.
- 黒枠（時空間図）をSpeed Matrixに変換，Gray levelに基づきScaled Matrixに変換する.
- Scaled Matrixに基づき，GLCMに変換する.

対象ネットワーク

首都圏へ流入する主要高速道路




首都圏へ流入する主要高速道路




今回は首都圏へ流入する主要高速道路
中央自動車道と**東名高速道路**の交通状態を
それぞれ接続する首都高速道路の**新宿線**
および**渋谷線**の交通状態から予測する。



首都圏へ流入する主要高速道路



首都圏へ流入する主要高速道路（簡易版）



首都圏へ流入する主要高速道路（簡易版）

2017-08-06 06:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）

2017-08-06 07:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 08:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 09:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 10:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）

2017-08-06 11:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 12:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 13:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 14:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 15:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 16:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）

2017-08-06 17:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 18:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 19:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）

2017-08-06 20:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）


2017-08-06 21:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）

2017-08-06 22:00:00



上記簡易ネットワークは検知器設置区間を元に作成

首都圏へ流入する主要高速道路（簡易版）

2017-08-06 23:00:00




上記簡易ネットワークは検知器設置区間を元に作成

時空間図として整理

横軸を時刻，縦軸を位置（区間番号・キロポスト）として
速度の時間的変動を 1 枚の画像として認識できるよう整理.

speed
(km/h)

時間
区間



日毎・時間帯毎

GLCMを用いた時空間図の合成

本作品では…

- STEP 1 各種時空間図を一定の時間幅（8時間）ごとに分割
- STEP 2 予測対象時間帯の1ステップ前の首都高速道路の時空間図を用いて、GLCMにより類似するパターンの時空間図を取得
- STEP 3 類似すると判定された日時の次の時間幅に対応する中央道or東名道の時空間図を類似度上位から一定数取得し、それぞれGLCMの類似度に応じた重みを付けた上で重ね合わせる。

という手順のプログラムを構築した。

**Python3.0を用いて実装し、審査期間中はGitHubでコードを公開
（スポンサー提供の臨時公開データをインプットとしていたため
現在は公開停止中）**


分析結果

設定

現在時刻 : 8月18日 16時
予測対象 : 東名道の16時から24時
インプット : 渋谷線の 8時から16時

渋谷線


現在時刻 16:00



この部分でパターン認識

東名道

この部分を予測したい




時刻

類似パターンの日程抽出

渋谷線 (2017/8/18)

現在時刻 (例)



赤枠部分と類似するパターンの
時空間図 (日付) を抽出


左図と (赤枠部分が) 類似していると
判定された画像



予測対象

東名道 (2017/8/18)

現在時刻 (例)



赤枠の部分（現在観測不可能）を
予測するため，類似候補日の
時空間図（右図）を重ね合わせる


前ページ抽出日と対応する時空間図



(2017/8/13)




(2017/8/12)



(2017/8/14)



(2017/8/26)




(2017/8/19)

判定時刻の次タイムステップのみ抽出

予測対象


東名道 (2017/8/18)

現在時刻 (例)



赤枠の部分（現在観測不可能）を
予測するため，類似候補日の
時空間図（右図）を重ね合わせる

前ページ抽出日と対応する時空間図





これらを類似度に応じた重み付けにより
合成したものが予測時空間図となる。

予測した時空間図の一例（東名道）

8月18日の東名道の実際の交通状態（左図）と，首都高速道路渋谷線の交通状態画像から，交通状態を予測したもの（右図）

（設定時刻までの8時間分の首都高速の交通状態をインプットとして東名道の8時間先までの交通状態を予測したケースを例示）




実際に観測された交通状態（正解）

本手法で予測した交通状態


予測した時空間図の一例（中央道）

8月19日の中央道の実際の交通状態（左図）と，首都高速道路新宿線の交通状態画像から，交通状態を予測したもの（右図）

（設定時刻までの8時間分の首都高速の交通状態をインプットとして東名道の8時間先までの交通状態を予測したケースを例示）



実際に観測された交通状態（正解）



本手法で予測した交通状態

まとめ

まとめ

画像認識系の機械学習手法を用いて，過去の時空間パターンから将来の時空間図を予測する手法を実装した．

予測した時空間図は，実際に観測された渋滞パターン（渋滞の前頭・末尾など）を捉えられていた．

参考文献

- 1) Hall-Bayer, M., GLCM Texture. A Tutorial, Version 2.3., Department of Geography, University of Calgary, Calgary, Alberta, Canada, 2000.
- 2) Zhang, Z., Wang, Y., Chen, P., He, Z., Yu, G., Probe data-driven travel time forecasting for urban expressways by matching similar spatiotemporal traffic patterns. Transport. Res. Part C Emerging Technol. 85, pp. 476-493, 2017.