



REFERAT NAUKOWY / WYNIKI PRAC B+R

Metodyka krótkoterminowej predykcji warunków ruchowych

dla algorytmów dynamicznego trasowania pojazdów
w inteligentnych systemach transportowych

Od danych GPS i modeli ML do decyzji algorytmu VRP

Katarzyna Marczuk | Aleet

Projekt Livable Cities • badania 2021–2023 • 27 października 2026



Od badań nad mobilnością do decyzji operacyjnych

Dlaczego prognozowanie ruchu jest ważnym problemem badawczym dla Aleet?

PRELEGENTKA

Katarzyna Marczuk

Założycielka i CEO Aleet

- Badania nad systemami mobility-on-demand
- Doktorat, National University of Singapore we współpracy z MIT (2016)
- Prowadzenie projektu B+R Livable Cities

Od badań nad mobilnością do decyzji operacyjnych

Dlaczego prognozowanie ruchu jest ważnym problemem badawczym dla Aleet?

PRELEGENTKA

Katarzyna Marczuk

Założycielka i CEO Aleet

- Badania nad systemami mobility-on-demand
- Doktorat, National University of Singapore we współpracy z MIT (2016)
- Prowadzenie projektu B+R Livable Cities

O ALEET

Decision Intelligence dla logistyki

Łączymy prognozowanie, modele operacyjne i optymalizację, aby wspierać decyzje o trasach i przydziałach.

PROGNOZA

ruch i popyt



CZAS DOJAZDU

ETA / macierz



DECYZJA

trasa / przydział

Od badań nad mobilnością do decyzji operacyjnych

Dlaczego prognozowanie ruchu jest ważnym problemem badawczym dla Aleet?

PRELEGENTKA

Katarzyna Marczuk

Założycielka i CEO Aleet

- Badania nad systemami mobility-on-demand
- Doktorat, National University of Singapore we współpracy z MIT (2016)
- Prowadzenie projektu B+R Livable Cities

O ALEET

Decision Intelligence dla logistyki

Łączymy prognozowanie, modele operacyjne i optymalizację, aby wspierać decyzje o trasach i przydzielach.

PROGNOZA

ruch i popyt



CZAS DOJAZDU

ETA / macierz



DECYZJA


trasa / przydział

DLACZEGO TO BADAMY? Błąd czasu przejazdu może zmienić trasę i przydział pojazdu – nie tylko ETA.

Trasa najlepsza teraz może nie być najlepsza za 30 minut

Warunki ruchu zmieniają się pomiędzy wyznaczeniem planu a realizacją przejazdu.

Przewidywany czas przejazdu w zależności od godziny wyjazdu




Ilustracja koncepcyjna; mechanizm opisany w raporcie, zał. 4, s. 2–5.

Trasa najlepsza teraz może nie być najlepsza za 30 minut

Warunki ruchu zmieniają się pomiędzy wyznaczeniem planu a realizacją przejazdu.

Przewidywany czas przejazdu w zależności od godziny wyjazdu



PYTANIE BADAWCZE

Czy prognoza ruchu poprawi wybór trasy i pojazdu?

Na wykresie wartości ilustracyjne – nie wyniki projektu.

Prędkość, natężenie i ETA to trzy różne wielkości

To rozróżnienie jest kluczowe do poprawnego odczytania późniejszych wyników.

PRĘDKOŚĆ

45 km/h

Jak szybko porusza się potok pojazdów?

Wynik eksperymentu: prognoza na 1 h

NATĘŻENIE

700 poj./h

Ile pojazdów przejeżdża przez odcinek?

Wynik eksperymentu: 15 i 30 min

ETA / CZAS

18 min

Ile zajmie dojazd od A do B?

Obliczane z sieci i przewidywanej prędkości

Trzy eksperymenty – dwa zadania predykcji i test decyzji

Najpierw mierzymy błąd prognozy; potem pytamy, czy prognoza poprawia wynik VRP.

A • PREDYKCJA

Średnia prędkość

horyzont 1 godzina

B • PREDYKCJA

Natężenie ruchu

horyzonty 15 i 30 minut

C • SYMULACJA

AGCRN → macierz czasów → VRP

Model natężenia oceniono osobno; eksperyment VRP porównywał macierze czasów z prędkości.

Dwa miliardy punktów GPS nie oznaczają pełnego obrazu ruchu

Floating Car Data (FCD): obserwujemy tylko pojazdy należące do próby pomiarowej.

**2 036 055
253**
punktów GPS

Warszawa i okolice

01.03.2019–01.03.2022

1

POMIAR GPS

pozycja + czas

2

MAP MATCHING

przypisanie do ulicy

3

AGREGACJA


prędkość na odcinku

Kontekst: ostrzeżenia pogodowe IMGW + wypadki drogowe

Najtrudniejszy problem: brak obserwacji w ponad 90% pól

Pole oznacza: konkretny odcinek drogi × konkretny przedział 15 minut.

Ilustracja macierzy segment × czas



● obserwacja FCD ● brak obserwacji

Porównaliśmy dwa sposoby uzupełniania

Graf drogowy

wartości z połączonych odcinków

Siatka sześciokątów


uśrednianie w najbliższym obszarze

W eksperymencie lepsza była interpolacja grafowa.

Najtrudniejszy problem: brak obserwacji w ponad 90% pól

Pole oznacza: konkretny odcinek drogi × konkretny przedział 15 minut.

Ilustracja macierzy segment × czas



● obserwacja FCD ● brak obserwacji

Porównaliśmy dwa sposoby uzupełniania

Graf drogowy

wartości z połączonych odcinków

Siatka sześciokątów

uśrednianie w najbliższym obszarze

W eksperymencie lepsza była interpolacja grafowa.

Ryzyko: model uczy się także na wartościach oszacowanych, nie tylko zmierzonych.

Jak z przeszłych obserwacji powstaje prognoza na kolejną godzinę?

Schemat doświadczenia predykcji średniej prędkości.

HISTORIA: 16 obserwacji co 15 minut = 4 godziny



16 wartości → 4 średnie godzinowe → predykcja średniej prędkości

Oddzielnie oceniano predykcję natężenia na 15 i 30 minut.

Sześć modeli sprawdzało różne sposoby rozumienia ruchu

Punkt odniesienia jest konieczny: złożony model powinien pokazać przewagę nad prostszym.

ARIMA

statystyczny baseline

Przeszłe wartości jednego szeregu

1 model

LSTM

pamięć czasu

Wzorce zmian w kolejnych chwilach

1 model

CNN · SAE

wzorce w danych

Lokalne zależności / reprezentacje

2 modele

TGCN · AGCRN

graf + czas


Zależności między odcinkami

2 modele

AGCRN uczy się, które odcinki są ze sobą powiązane


„Sąsiedztwo” w modelu może oznaczać zależność ruchową, a nie tylko wspólną ulicę.

SIEĆ DROGOWA



Fizyczne połączenia ulic

RELACJE WYUCZONE



Powiązanie statystyczne ≠ nowa droga

AGCRN = adaptacyjny graf + mechanizm pamięci czasowej GRU

Modelu nie wystarczy wytrenować – trzeba go uczciwie sprawdzić

Dane do uczenia, doboru parametrów i końcowego testu pełnią różne role.

Podział opisany w raporcie




Dobre: wspólne metryki i punkt odniesienia

Do doprecyzowania: czy podział był chronologiczny?

Dlaczego MAE i RMSE mogą wskazywać różnych zwycięzców?

MAE opisuje typowy błąd bezwzględny, RMSE mocniej obciąża duże pomyłki.

Przykład: cztery błędy predykcji [km/h]



MAE = 2,5 km/h

Średni bezwzględny błąd


RMSE $\approx$ 3,6 km/h

Większa kara za pojedynczy duży błąd

MAPE podaje błąd procentowy, ale nie oznacza „odsetka trafnych prognoz”.

Jedna prognoza może dobrze śledzić trend, ale wygładzać skrajności

Rzeczywisty wykres modelu AGCRN dla wybranego segmentu ulicy.



Jak czytać wykres?


- ✓ **uchwycony trend**
- ✓ **stabilniejsza prognoza**
- ! **możliwy błąd w ekstremach**

Jeden odcinek nie dowodzi dokładności całego modelu.

AGCRN: najniższy średni błąd prognozy prędkości na 1 h

Porównanie MAE modelu; mniejsze wartości są lepsze.

MAE [m/s] – horyzont jednej godziny



AGCRN

0,49

m/s MAE $\approx$ 1,76 km/h

5,75%

MAPE – średni błąd procentowy

Prognoza natężenia: różne metryki dają różny ranking modeli

W tych tabelach nie mierzymy prędkości, tylko liczbę pojazdów w przedziale czasu.

HORYZONT / METRYKA	AGCRN	CNN	LEPSZY
15 min / MAE	7,47	7,98	AGCRN
15 min / RMSE	33,73	28,57	CNN
30 min / MAE	7,58	11,10	AGCRN
30 min / RMSE	33,67	29,88	CNN

AGCRN miał niższy przeciętny błąd; CNN lepiej wypadał w miarze karzącej duże pomyłki.

Prędkość nie jest kosztem trasy – trzeba ją przeliczyć na czas

W uproszczeniu: czas odcinka = jego długość ÷ przewidywana prędkość.

Dla odcinka drogi:

$$t \approx L \div v$$

L – długość odcinka

$\hat{v}$ – prognozowana prędkość

Przykład ilustracyjny: dwa warianty przejazdu

TRASA A

12 km ÷ 20 km/h

36 min

TRASA B


14 km ÷ 35 km/h

24 min

Dłuższa trasa może mieć krótszy ETA.

W VRP prognoza wpływa na to, które przydziały są wykonalne

Badany przypadek: dynamiczne współdzielenie przejazdów (ride-pooling).



Algorytm rozstrzyga:

- który pojazd obsłuży zlecenie
- w jakiej kolejności stopów
- czy dotrzynamy ograniczeń czasu

Aktualizacja ETA może zmienić wybór.

Jak wyizolowaliśmy wpływ informacji o ruchu na wynik VRP?

Trzy źródła macierzy czasów; ta sama sieć, flota i metoda trasowania.

AGCRN

Prognoza prędkości

HISTORIA

Średnia z 6 tygodni

RUCH SWOBODNY

Bez prognozy zatłoczenia

STAŁY ALGORYTM • STAŁY SCENARIUSZ • ZMIENNA MACIERZ CZASÓW

10 000

pojazdów

17 h

07:00–24:00

210 408

zleceń w opisie testu

AGCRN: najkrótszy średni czas oczekiwania w symulacji

To wynik operacyjny floty, nie bezpośredni wskaźnik błędu ETA.

Średni czas oczekiwania na pojazd

AGCRN



23:27

Średnia historyczna



28:29

Ruch swobodny



30:47

-18%

vs historia

-24%

vs ruch swobodny

Pozostałe wyniki poprawiły się nierównomiernie


Wyższa obsada pojazdu nie musi oznaczać lepszego czasu oczekiwania.

WSKAŹNIK	AGCRN	HISTORIA	RUCH SWOBODNY
Zlecenia obsłużone	69,38%	67,07%	68,86%
Udział pustych km	11,59%	12,69%	11,96%
Obsada niepełnego auta	1,67	1,60	1,72


Średnia ukrywa dynamikę: kiedy modele różnią się najbardziej?

Wykresy z raportu: rozkład czasu oczekiwania w ciągu dnia dla dwóch wariantów.

AGCRN



HISTORIA / 6 TYGODNI



Uwaga: różne zakresy osi Y – nie porównuj wysokości krzywych bez odczytania skali.

Co wynik rzeczywiście potwierdza – a czego jeszcze nie?

Rozdzielenie walidacji modelu, efektu symulacyjnego i efektu produkcyjnego.

WYKAZANO

- Porównanie modeli na badanych danych
- Niższy MAE prędkości dla AGCRN
- Krótsze oczekiwanie w symulacji VRP

NIE WYKAZANO WPROST

- Błędu ETA na rzeczywistych przejazdach
- 18% korzyści w realnym wdrożeniu
- Statystycznej istotności efektu VRP

DO DOPRECYZOWANIA

- Chronologia podziału train/test
- Wkład pogody i incydentów (abłacja)
- Powtarzalność i zakres innych miast

Wniosek: mamy wynik eksperymentalny i symulacyjny – nie deklarację gwarantowanego efektu wdrożeniowego.

Trzy wnioski i trzy naturalne kierunki dalszych badań

Od danych i grafu, poprzez trafność prognozy, do użyteczności decyzji.

01

Jakość danych i interpolacji

Duża liczba pomiarów nie usuwa problemu braków w sieci.

02

Predykcja czasowo-przestrzenna

AGCRN dał najniższy MAE prędkości na badanym zbiorze.

03

Wpływ na decyzje transportowe

W symulacji lepsza macierz czasów skróciła oczekiwanie.

Następne kroki

walidacja ETA • kolejne miasta • testy w eksploatacji

Podstawa metodyczna i literatura

Do pozostawienia na ekranie podczas pytań.

- Aleet (2023). Raport z realizacji fazy badawczej B+R, POIR.01.01.01-00-1019/20, załącznik 4 (etap 3).
- **Opióła P., Jasiński P., Witkowski I., Stec K., Reps B., Marczuk K. (2023). Traffic Prediction for VRP in Intelligent Transportation Systems. Springer LNNS 724.**
- Bai L. i in. (2020). Adaptive Graph Convolutional Recurrent Network for Traffic Forecasting. NeurIPS 33.
- Zhao L. i in. (2020). T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction. IEEE T-ITS.
- Yang C., Gidófalvi G. (2018). Fast map matching integrating HMM with precomputation. IJGIS.

Publikacja naukowa: https://doi.org/10.1007/978-3-031-35314-7_14

