

***Efektywność rekurencyjnych
sieci neuronowych LSTM i GRU
wytrenowanych do predykcji
ruchu drogowego
w porównaniu z metodami
statystycznymi***

Andrzej Czyżewski, Andrzej Sroczyński


Politechnika Gdańska, Katedra Systemów Multimedialnych

Motywacja badań:

- zastosowanie wyników w inteligentnych znakach drogowych (Projekt INZNAK – *Intelligentne znaki drogowe do adaptacyjnej regulacji ruchu pojazdów*)
- Potrzeba uwzględnienia aktualnego stanu ruchu drogowego w doborze zalecanej prędkości jazdy

Koncepcja systemu


Schemat blokowy systemu inteligentnych znaków drogowych




Koncepcja systemu

Schemat blokowy systemu łączności inteligentnych znaków drogowych



Zasoby sieciowe, zarządzanie




Struktura Inteligentnego Znak Drogowego




A 3D diagram of a cube with a coordinate system. The origin O is at the back-bottom-left corner. The axes are labeled $O \hat{x} OX$, $O \hat{y} OY$, and $O \hat{z} OZ$. Six measurement points are indicated by arrows and labels: m_1, x_1 (front-bottom-left face), m_2, x_2 (front-bottom-right face), m_3, y_1 (top-left face), m_4, y_2 (top-right face), m_5, z_1 (bottom face), and m_6, z_2 (top face). Dashed lines extend from the origin along the axes.



Instalacja testowa systemu pomiarowego




Prototyp Inteligentnego Znaku Drogowego



Instalacja testowa Inteligentnego Znaku Drogowego



Implementacja sztucznych sieci neuronowych



Przykład predykcji natężenia ruchu

Zastosowane modele:

1. Wielowarstwowe sieci rekurencyjne typu LSTM
2. Wielowarstwowe sieci rekurencyjne typu GRU
3. Trójwarstwowa sieć typu auto-encoder

Przykład predykcji natężenia ruchu

Zestawy danych:

1. Do treningu i walidacji modeli - rzeczywiste dane pomiarowe udostępnione przez Kalifornijski Departament Transportu (CalTrans) na stronie internetowej Caltrans Performance Measurement System (PeMS)
2. Do testów - zsyntetyzowany zestaw danych uzyskany przy użyciu oprogramowania do symulacji mikroskopowej Vissim (inferencja)

Przykład predykcji natężenia ruchu

Dane o natężeniu ruchu z systemu PeMS, zebrane w maju 2022 r., były agregowane z okresem 5 minut.

Podzielono je na dwa zbiory:

- uczący, 4 377 rekordów, zawierający dane od 1 do 16 maja
- walidacyjny, 1 095 rekordów, zawierający dane od 16 do 19 maja.

Przykład predykcji natężenia ruchu

Dane testowe zostały wygenerowane przy użyciu symulatora Vissim (PTV Group), z wykorzystaniem modelu Wiedemann 99.


Program skalibrowano zgodnie z zaleceniami producenta oraz zaleceniami Departmentu Transportu Florydy (*Traffic Analysis Handbook. A Reference for Planning and Operations*. Florida Department of Transportation, 2014) i w oparciu o dane PeMS z okresu od 1 do 7 maja.

Przykład predykcji natężenia ruchu

Środowisko testów


- komputer z sześciordzeniowym procesorem Intel Core i7-6800k @ 3,40 GHz, 64 GB pamięci RAM
- karta graficzna NVIDIA GeForce GTX 1070
- MS Windows 10 Pro
- Python 3.6.15
- Keras-gpu 2.1.3

Straty uczenia – porównanie modeli




Średni błąd procentowy między wartością przewidywaną a rzeczywistą dla zestawu walidacyjnego oraz modeli LSTM, GRU i SAE.

Straty uczenia - LSTM




Średni błąd procentowy między wartością przewidywaną a rzeczywistą dla zestawu walidacyjnego dla czterech modeli LSTM.

Straty uczenia - GRU



Średni błąd procentowy między wartością przewidywaną a rzeczywistą dla zestawu walidacyjnego dla czterech modeli GRU.


Rezultat predykcji dla 5-dniowego przedziału czasowego



Metryki błędów predykcji

	LSTM	GRU	SAE
explained_variance_score	0,982213	0,982460	0,981234
mape	0,084427	0,089500	0,082789
mae	0,031964	0,029042	0,030540
mse	0,001666	0,001433	0,001550
rmse	0,040818	0,037861	0,039366
r2	0,979565	0,982418	0,980993

Rezultat predykcji dla 24-godzinnego przedziału czasowego



scientific reports

[Explore content](#) ▾

[About the journal](#) ▾

[Publish with us](#) ▾

[nature](#) > [scientific reports](#) > [articles](#) > article

Article | [Open Access](#) | [Published: 04 September 2023](#)

Road traffic can be predicted by machine learning equally effectively as by complex microscopic model

[Andrzej Sroczyński](#)  & [Andrzej Czyżewski](#)

[Scientific Reports](#) **13**, Article number: 14523 (2023) | [Cite this article](#)

327 Accesses | [Metrics](#)

Received 11 January 2023, accepted 17 January 2023, date of publication 20 January 2023, date of current version 25 January 2023.

Digital Object Identifier 10.1109/ACCESS.2023.3238578



RESEARCH ARTICLE

Examining the Impact of Distance Between VSL Road Signs on Vehicle Speed Variance

ANDRZEJ SROCZYŃSKI¹, AND **ANDRZEJ CZYŻEWSKI²**, (Member, IEEE)

¹TSTRONIC Sp. z o.o., 83-011 Gdańsk, Poland

²Faculty of Electronics, Telecommunications and Informatics, Gdańsk University of Technology, 80-233 Gdańsk, Poland

Corresponding author: Andrzej Sroczyński (andrzej.sroczynski@siled.pl)

This work was supported by the Polish National Centre through the Research and Development Project (NCBR), European Regional Development Fund “INZNAK: Intelligent Road Signs with V2X Interface for Adaptive Traffic Controlling,” under Grant POIR.04.01.04-00-0089/16.



remote sensing

Examining Impact of Speed Recommendation Algorithm Operating in Autonomous Road Signs on Minimum Distance between Vehicles

by  Andrzej Sroczyński ^{1,*} ,  Adam Kurowski ²  ,  Szymon Zaporowski ²   and  Andrzej Czyżewski ²  

¹ TSTRONIC Sp. z o.o., Benzynowa 19, 83-011 Gdansk, Poland

² Multimedia Systems Department, Faculty of Electronics, Telecommunications and Informatics, Gdansk University of Technology, Narutowicza 11/12, 80-233 Gdansk, Poland

* Author to whom correspondence should be addressed.

Remote Sens. **2022**, *14*(12), 2803; <https://doi.org/10.3390/rs14122803>

Received: 3 May 2022 / Revised: 3 June 2022 / Accepted: 8 June 2022 / Published: 10 June 2022

(This article belongs to the Special Issue **Integrating Remote Sensing Data for Transportation Asset Management**)

Dziękuję za uwagę

Praca została zrealizowana w ramach projektu POIR.04.01.04-00-0089/16, zatytułowanego INZNAK - „Inteligentne znaki drogowe do adaptacyjnego sterowania ruchem pojazdów, komunikujące się w technologii V2X”, który jest dofinansowywany przez Narodowe Centrum Badań i Rozwoju ze środków Europejskiego Funduszu Rozwoju Regionalnego.