

Cybersecurity and Law

2025 Nr 2 (14)

DOI: 10.34567/cal/215904



Map-matching and vehicle trajectory prediction using artificial intelligence methods

Map-matching i predykcja trajektorii ruchu pojazdu z wykorzystaniem metod sztucznej inteligencji

Tomasz Waksmundzki

Politechnika Warszawska

ORCID: 0009-0008-4732-3233

E-mail: tomasz.waksmundzki@outlook.com

Abstract

Vehicle movement data sets, obtained mainly from GNSS systems, are characterised by inaccuracy, which negatively affects the reliability of analyses. In response to this challenge, this paper provides an overview of map-matching techniques and trajectory prediction algorithms. The aim of map matching is to accurately reconstruct the actual route of a vehicle, which forms the basis for further actions. Based on the reconstructed trajectory, prediction algorithms can forecast further movement, which allows for the monitoring of transport and the detection of anomalies, as well as supporting intelligent traffic management by forecasting future traffic volumes.

The article uses a systematic literature review and comparative analysis. It presents a broad overview of methods for performing map-matching tasks and techniques for predicting vehicle trajectories.

The results discuss the detailed evolution of these techniques. A cross-section of solutions is presented, ranging from basic geometric and probabilistic models to advanced modern solutions using deep artificial neural networks.

The summary points to the concept of unifying both processes in a single architecture. This approach has been identified as a potential opportunity to significantly increase the accuracy and reliability of geolocation data processing systems in future applications.

Keywords

map matching; vehicle motion trajectory prediction; intelligent transport; machine learning

Streszczenie

Zbiory danych o ruchu pojazdów, pozyskiwane głównie z systemów GNSS, charakteryzują się niedokładnością, co negatywnie wpływa na niezawodność analiz. W odpowiedzi na to wyzwanie, niniejsza praca stanowi przegląd technik dopasowania

do mapy (ang. map-matching) oraz algorytmów predykcji trajektorii. Celem map-matchingu jest precyzyjna rekonstrukcja rzeczywistej trasy pojazdu, co stanowi bazę dla dalszych działań. Na podstawie tak odtworzonej trajektorii, algorytmy predykcji mogą prognozować dalszy ruch, co pozwala na monitorowanie transportów i wykrywanie anomalii, a także wspiera inteligentne zarządzanie ruchem poprzez prognozowanie przyszłego natężenia.

W artykule zastosowano metodę systematycznego przeglądu literatury oraz analizy porównawczej. Przedstawiono szeroki przegląd metod realizacji zadań map-matchingu oraz technik służących do predykcji trajektorii ruchu pojazdu. W ramach wyników omówiono szczegółową ewolucję tych technik. Zaprezentowano przekrój rozwiązań, poczynając od podstawowych modeli geometrycznych i probabilistycznych, aż po zaawansowane współczesne rozwiązania wykorzystujące głębokie sztuczne sieci neuronowe.

W podsumowaniu wskazano na koncepcję unifikacji obu procesów w jednej architekturze. Zidentyfikowano to podejście jako potencjalną możliwość znaczącego zwiększenia dokładności i niezawodności systemów przetwarzania danych geolokalizacyjnych w przyszłych zastosowaniach.

Słowa kluczowe

map-matching; predykcja trajektorii ruchu pojazdu; inteligentny transport; uczenie maszynowe

Wprowadzenie

Dynamiczny postęp w dziedzinie technologii geolokalizacyjnych, który obserwowany w ostatnich latach, umożliwił gromadzenie i analizę rozległych zbiorów danych dotyczących ruchu pojazdów. Kluczową rolę w tym procesie odgrywają dane pozyskiwane z GNSS (ang. Global Navigation Satellite Systems), takich jak GPS czy Galileo. Surowe dane geolokalizacyjne charakteryzują się niedokładnością, co może być nieakceptowalne w przypadku bezpośredniego zastosowania ich w rozwiązaniach wymagających dużej precyzji. Opieranie analiz bezpośrednio na takich danych może skutkować nieprawidłowymi wnioskami oraz projektowaniem nieoptymalnych systemów¹. Niedokładności te wynikają głównie z zakłóceń propagacji sygnału, takich jak jego odbicia w terenie zabudowanym², czy też spowodowanych fizyką atmosfery³. Istotny wpływ mają również niedoskonałości samego sprzętu, w tym

¹ G. Hu, J. Shao, F. Liu, Y. Wang, H. T. Shen, If-matching: Towards accurate map-matching with information fusion, „IEEE Transactions on Knowledge and Data Engineering” 2017, t. 29, s. 114-127, DOI:10.1109/TKDE.2016.2617326.

² W. Chen, Z. Li, M. Yu, Y. Chen, Effects of sensor errors on the performance of map matching, „Journal of Navigation” 2005, t. 58, s. 273-282, DOI:10.1017/S0373463305003164.

³ A. Mohanty, G. Gao, A survey of machine learning techniques for improving global navigation satellite systems, „EURASIP Journal on Advances in Signal Processing” 2024, s. 1-40, DOI:10.48550/arXiv.2406.16873.

błędy zegarów odbiorników⁴ oraz odchylenia w danych orbitalnych satelitów⁵. Aby zwiększyć użyteczność danych geolokalizacyjnych, stosuje się różne techniki ich przetwarzania. Jedną z najpopularniejszych jest dopasowanie do mapy (ang. map-matching), które polega na określeniu rzeczywistej trasy pojazdu na cyfrowej mapie drogowej na podstawie zarejestrowanej sekwencji jego pozycji⁶. Zastosowanie techniki dopasowania do mapy jest fundamentalne dla podniesienia poziomu niezawodności rozwiązań, w których precyzyjne określenie pozycji pojazdu ma krytyczne znaczenie. W ITS (ang. Intelligent Transport System), szczególnie w kontekście elektronicznego poboru opłat, map-matching eliminuje niejednoznaczności, gwarantując przypisanie pojazdu do właściwego, płatnego segmentu infrastruktury i tym samym zapobiegając błędnemu naliczeniu należności. Dla sektora zarządzania flotą i logistyki, technika ta dostarcza zweryfikowanych danych o pokonanych trasach, co stanowi podstawę dla wiarygodnej analizy efektywności operacyjnej. Najwyższy stopień niezawodności jest jednak wymagany w dziedzinie pojazdów autonomicznych i ADAS (ang. Advanced Driver Assistance Systems), gdzie precyzja pozycjonowania jest kluczowym elementem procesów fuzji danych multimodalnych, łączących odczyty z GPS z danymi z innych sensorów, takich jak LiDAR (ang. Light Detection and Ranging)⁷ czy kamery⁸, w celu uzyskania maksymalnie wiarygodnej percepcji otoczenia pojazdu. Zrekonstruowana trajektoria pojazdu może stanowić dane wejściowe dla algorytmów predykcji jego dalszej trajektorii ruchu. Na podstawie analizy dotychczasowego przebiegu trasy oraz wzorców historycznych, systemy te mogą estymować jej najbardziej prawdopodobny przyszły przebieg w sieci drogowej. Zdolność ta znajduje zastosowanie w systemach monitorowania transportów, gdzie umożliwia wczesne wykrywanie anomalii, takich jak odchylenie od wyznaczonego korytarza transportowego, co pozwala na szybszą ocenę potencjalnych zagrożeń i zwiększenie bezpieczeństwa publicznego. W obszarze inteligentnego zarządzania ruchem, predykcja pozwala na prognozowanie przyszłego natężenia na kluczowych odcinkach i aktywne sterowanie sygnalizacją w celu minimalizacji zatorów drogowych.

⁴ V. Zhilinskiy, L. Gagarina, T. Ishkova, E. Petrov, A. Petrova, Software package for solving navigation problem using systematic instrumental error correction, 2019, s. 1871–1875, DOI:10.1109/EIConRus.2019.8657157; G. Hu, J. Shao, F. Liu, Y. Wang, H. T. Shen, op.cit., s. 114-127.

⁴ W. Chen, Z. Li, M. Yu, Y. Chen, op.cit., s. 273.

⁴ A. Mohanty, G. Gao, op.cit., s. 1-40.

⁴ V. Zhilinskiy, et.al., op.cit., s; 1871.

⁴ O. Montenbruck, P. Steigenberger, M. Aicher, A long-term broadcast ephemeris model for extended operation of GNSS satellites, „Annual of Navigation” 2021, t. 68, nr 1, s. 199-215, DOI:10.1002/navi.404

⁴ Y. Liu, Z. Li, A novel algorithm of low sampling rate gps trajectories on map-matching, „EURASIP Journal on Wireless Communications and Networking” 2017, DOI:10.1145/1653771.1653820.

⁵ O. Montenbruck, P. Steigenberger, M. Aicher, op.cit., s. 199 i n.

⁶ Y. Liu, Z. Li, op.cit.


⁷ S. Jeong, H. Shin, M.-J. Kim, D. Kang, S.-W. Lee, S. Oh, Enhancing LiDAR Mapping with YOLO-Based Potential Dynamic Object Removal in Autonomous Driving, „Sensors (Basel, Switzerland)” 2024, t. 24, no. 23, DOI:10.3390/s24237578.

⁸ H. Wu, Z. Chen, W. Sun, B. Zheng & W. Wang, Modeling trajectories with recurrent neural networks, „Proceedings of the 26th International Joint Conference on Artificial Intelligence” 2017, s. 3083–3090, DOI:10.24963/ijcai.2017/430.

Dopasowanie do mapy

Map-matching to proces dopasowywania surowych danych GPS do map cyfrowych. Celem map-matchingu jest rekonstrukcja rzeczywistej trasy pojazdu na podstawie zaszumionych danych GPS. W zależności od wykorzystywanego algorytmu, w analizie uwzględniane są nie tylko współrzędne geograficzne pojazdu w czasie, ale także jego prędkość⁹ czy azymut¹⁰, a to wszystko rozpatrywane jest w kontekście geometrycznej i topologicznej struktury sieci dróg. Na rysunku 1 przedstawiono przykład wykorzystania map-matching'u..

Rys. 1. Proces map-matchingu: dopasowanie sekwencji surowych pomiarów GPS (punkty czerwone) do rzeczywistej sieci dróg na mapie (linia niebieska).



Źródło: opracowanie własne.

Jednym z podstawowych kryteriów podziału algorytmów map-matching jest przyjęta przez nie strategia przetwarzania danych, na podstawie której wyróżnia się metody online oraz offline¹¹. Algorytmy online dokonują dopasowania w czasie rzeczywistym, wykorzystując sekwencyjnie napływające punkty i ich kontekst historyczny, co sprawia, że wyznaczona trasa może być korygowana post factum, lub przy założeniu jej niezmienności, może dojść do

⁹ S. Taguchi, S. Koide, T. Yoshimura, Online map matching with route prediction, „IEEE Transactions on Intelligent Transportation Systems” 2019, t. 20, s. 338–347, DOI:10.1109/TITS.2018.2812147.

¹⁰ Z. Xiong, B. Li, D. Liu, Map-matching using Hidden Markov Model and path choice preferences under sparse trajectory, „Sustainability” 2021, t. 13, nr 22, DOI:10.3390/su132212820.

¹¹ S. Taguchi, S. Koide, T. Yoshimura, Online map matching with route prediction, „IEEE Transactions on Intelligent Transportation Systems” 2019, t. 20, s. 338–347, DOI:10.1109/TITS.2018.2812147.

nieśpójności całej trasy. Z kolei algorytmy offline wymagają dostępu do całej trajektorii przed rozpoczęciem analizy, co umożliwia globalną optymalizację i osiągnięcie wyższej dokładności, jednak wyklucza ich użycie w aplikacjach działających w czasie rzeczywistym.

Rozwój technik dopasowania do map to proces przechodzenia od prostych, intuicyjnych reguł do zaawansowanych, uczących się systemów, które coraz lepiej radzą sobie z niepewnością i złożonością danych GPS w kontekście map cyfrowych.

Początkowe metody, bazujące na analizie geometrycznej i topologicznej¹², opierały się na dwóch kryteriach: bliskości, czyli dopasowaniu punktu pomiarowego do najbliższego segmentem sieci drogowej, oraz spójności, weryfikującej ciągłość topologiczną wynikowej trajektorii. Pomimo niskiej złożoności obliczeniowej, rozwiązania te były podatne na błędy, co skutkowało generowaniem nielogicznych i nieśpójnych tras, zwłaszcza w złożonych sieciach drogowych.

Kolejnym, kluczowym kierunkiem ewolucji technik dopasowania do map stało się jawne modelowanie niepewności. Wynikało to z fundamentalnego założenia, że dane lokalizacyjne są z natury stochastyczne – obciążone nieodłącznym błędem i szumem pomiarowym. W rezultacie zadanie algorytmów uległo zmianie: zamiast deterministycznego przypisania, celem stało się wnioskowanie probabilistyczne, polegające na estymacji najbardziej wiarygodnej trajektorii w oparciu o nieprecyzyjne dane obserwacyjne. Do realizacji tego zadania wykorzystuje się szereg zaawansowanych technik, takich jak filtry cząsteczkowe (ang. particle filters)¹³, systemy oparte na logice rozmytej (ang. fuzzy logic)¹⁴ czy teoria Dempstera-Shafera (ang. Dempster–Shafer theory)¹⁵. Jednak, fundamentalnym i najszerzej stosowanym podejściem w tej dziedzinie jest HMM (ang. Hidden Markov Model), który opiera się na założeniu, że obserwacje (np. dane geolokalizacyjne) są rezultatem ukrytego procesu Markowa. Podejście to opiera się na definiowaniu dwóch kluczowych rozkładów prawdopodobieństwa: prawdopodobieństwa emisji, które wiąże obserwację GPS z możliwymi segmentami drogi, oraz prawdopodobieństwa przejścia, które określa prawdopodobieństwo przejazdu między sąsiednimi pozycjami w sieci drogowej. Oba te komponenty są następnie integrowane przez algorytm Viterbiego w celu znalezienia najbardziej prawdopodobnej trajektorii¹⁶. Poszczególni autorzy modyfikują te podstawowe komponenty, aby zwiększyć

¹² J. S. Greenfeld, Matching gps observations to locations on a digital map, „Transportation research board 81st annual meeting” 2002, t. 22, s. 576–582; M. A. Quddus, W. Y. Ochieng, L. Zhao, R. B. Noland, A general map matching algorithm for transport telematics applications, „GPS Solutions” 2003, t. 7, s. 157–167, DOI:10.1007/s10291-003-0069-z; D. Bernstein, A. Kornhauser, An introduction to map matching for personal navigation assistants, 1996.

¹³ K. Kempinska, T. O. Davies, J. Shawe-Taylor, Probabilistic map-matching using particle filters, „arXiv: Machine Learning” 2016, DOI:10.48550/arXiv.1611.09706; P. Davidson, J. Collin, J. H. Takala, Application of particle filters to a map-matching algorithm, „Gyroscopy and Navigation” 2011, t. 2, s. 285–292, DOI:10.1134/S2075108711040067.

¹⁴ Y. Zhang, Y. Gao, A fuzzy logic map matching algorithm, „2008 Fifth International Conference on Fuzzy Systems and Knowledge Discovery” 2008, t. 3, s. 132–136, DOI:10.1109/FSKD.2008.234; M. A. Quddus, R. B. Noland, W. Y. Ochieng, A high accuracy fuzzy logic based map matching algorithm for road transport, „Journal of Intelligent Transportation Systems” 2006, t. 10, s. 103–115, DOI:10.1080/15472450600793560.

¹⁵ G. Nassreddine, F. Abdallah, T. Denoeux, Map matching algorithm using interval analysis and dempster-shafer theory, „2009 IEEE Intelligent Vehicles Symposium” 2009, s. 494–499, DOI:10.1109/IVS.2009.5164328.

¹⁶ B. Hummel, Map matching for vehicle guidance, „Dynamic and mobile GIS” 2006, s. 211–222.

dokładność dopasowania, na przykład poprzez uwzględnienie trendu ruchu pojazdu¹⁷, różnicy w azymutach między obserwacją a segmentem drogi czy preferencji kierowcy co do wyboru ścieżki¹⁸. Inne podejścia wprowadzają funkcje kary za przekroczenie dozwolonej prędkości¹⁹, co pozwala lepiej odzwierciedlić realistyczne zachowania na drodze. Liczne warianty algorytmów HMM świadczą o dużej elastyczności tego podejścia. Mimo to, wspólnym i istotnym wyzwaniem praktycznym pozostaje konieczność starannej kalibracji parametrów modelu oraz potencjalna zależność od szczegółowych danych mapowych, co może wpływać na ich ogólną adaptacyjność.

Najnowszym etapem ewolucji algorytmów map-matching jest zastosowanie technik uczenia maszynowego, w szczególności głębokich sieci neuronowych. W przeciwieństwie do modeli probabilistycznych, takich jak HMM, które opierają się na z góry zdefiniowanych parametrach, systemy te uczą się złożonych zależności bezpośrednio z danych. Co kluczowe, proces uczenia obejmuje nie tylko ogromne zbiory historycznych trajektorii, ale również samą strukturę topologiczną mapy cyfrowej. Takie dwutorowe podejście znacząco rozszerza możliwości analityczne modelu. Analiza trajektorii pozwala na uwzględnienie subtelnych, kontekstowych informacji – jak typowe prędkości czy wzorce zachowań kierowców – podczas gdy uczenie się z topologii mapy pozwala modelowi zrozumieć wewnętrzną logikę sieci drogowej, np. prawdopodobieństwo wykonania konkretnych manewrów na skrzyżowaniach. Wśród stosowanych architektur dominują modele seq2seq, często z mechanizmem uwagi, które efektywnie przekształcają sekwencje danych geolokalizacyjnych na sekwencje segmentów drogowych²⁰. Wykorzystuje się również CNN (ang. Convolutional Neural Network) do analizy zależności przestrzennych oraz RNN (ang. Recurrent Neural Network) do modelowania czasowego charakteru trajektorii²¹. Coraz częściej stosowane są także GNN (ang. Graph Neural Network), które bezpośrednio włączają strukturę sieci drogowej w proces uczenia²², oraz techniki uczenia przez wzmacnianie (ang. Reinforcement Learning), gdzie dopasowanie trasy jest traktowane jako zadanie decyzyjne²³. Mimo dużej skuteczności, praktyczne wdrożenie modeli głębokiego uczenia wiąże się ze znacznymi wyzwaniami, takimi jak zapotrzebowanie na

¹⁷ H. Y. Song, J. H. Lee, A map matching algorithm based on modified Hidden Markov Model considering time series dependency over larger time span, „Heliyon” 2023, t. 9, nr 11, DOI:10.1016/j.heliyon.2023.e21368.

¹⁸ Z. Xiong, B. Li, D. Liu, Map-matching using Hidden Markov Model and path choice preferences under sparse trajectory, „Sustainability” 2021, t. 13, nr 22, DOI:10.3390/su132212820.

¹⁹ C. Y. Goh, J. Dauwels, N. Mitrovic, M. T. Asif, A. Oran, P. Jaillet, Online map-matching based on Hidden Markov Model for real-time traffic sensing applications, „2012 15th International IEEE Conference on Intelligent Transportation Systems” 2012, s. 776–781, DOI:10.1109/ITSC.2012.6338627.

²⁰ J. Feng, Y. Li, K. Zhao, Z. Xu, T. Xia, J. Zhang, D. Jin, DeepMM: Deep learning based map matching with data augmentation, „IEEE Transactions on Mobile Computing” 2022, t. 21, nr 7, s. 2372–2384, DOI:10.1109/TMC.2020.3043500.

²¹ Z. Liu, J. Fang, Y. Tong, M. Xu, Deep learning enabled vehicle trajectory map-matching method with advanced spatial-temporal analysis, „IET Intelligent Transport Systems” 2020, t. 14, nr 14, s. 2052–2063, DOI:10.1049/iet-its.2020.0486.

²² Y. Liu, Q. Ge, W. Luo, Q. Huang, L. Zou, H. Wang, X. Li, C. Liu, GraphMM: Graph-based vehicular map matching by leveraging trajectory and road correlations, „IEEE Transactions on Knowledge and Data Engineering” 2024, t. 36, nr 1, s. 184–198, DOI:10.1109/TKDE.2023.3287739.


²³ Z. Shen, K. Yang, X. Zhao, J. Zou, W. Du, J. Wu, DMM: A deep reinforcement learning based map matching framework for cellular data, „IEEE Transactions on Knowledge and Data Engineering” 2024, t. 36, nr 10, s. 5120–5137, DOI:10.1109/TKDE.2024.3383881.

wysokiej jakości zbiory danych oraz wysokie koszty obliczeniowe. Ponadto zapewnienie ich niezawodności w dynamicznie zmieniających się warunkach wymaga ciągłego monitorowania i ponownego trenowania, co jest znacznym utrudnieniem wdrożeniowym.

Predykcja trasy pojazdów

Predykcja trajektorii pojazdu to proces przewidywania przyszłej trajektorii pojazdu na podstawie dotychczas przebytej trasy oraz bazując danych historycznych. Na rysunku 2 przedstawiono przykładowe zastosowanie predykcji trajektorii ruchu pojazdu.

Rys. 2. *Proces predykcji trajektorii pojazdu: krótkoterminowa predykcja trajektorii pojazdu (linia żółta) stanowiąca kontynuację jego obecnej, dopasowanej do mapy trasy (linia niebieska), która została wyznaczona na podstawie surowych pomiarów GPS (punkty czerwone) oraz danych historycznych.*



Źródło: opracowanie własne.

Jednym z podejść do predykcji trajektorii pojazdu są modele probabilistyczne, które traktują przyszłą trasę jako zmienną losową, a jej najbardziej prawdopodobny przebieg estymują na podstawie dotychczasowego przebiegu trasy pojazdu lub danych historycznych. W HMM, na podstawie obserwowanej, częściowej trasy (np. sekwencji kluczowych punktów na drodze) wnioskuje się o przyszłej trajektorii pojazdu²⁴ lub celu podróży²⁵, które są zdefiniowane jako stan ukryty. Alternatywnie, inne podejście probabilistyczne²⁶ integruje model fizycznego ruchu pojazdu z danymi historycznymi w architekturze filtru Bayesowskiego. W takim rozwiązaniu filtr Kalmana służy do bieżącej estymacji rozkładu prędkości pojazdu, co w połączeniu z modelem przejść między segmentami drogi, wytrenowanym na historycznych trajektoriach, pozwala na krótkoterminowe prognozowanie najbardziej prawdopodobnej przyszłej trasy.

²⁴ R. Chawuthai, K. Kawachakul, K. Boonrod, T. Threepak, Route prediction from gps trajectory and road data, „2023 15th International Conference on Computer and Automation Engineering (ICCAE)” 2023, s. 65–69, DOI:10.1109/ICCAE56788.2023.10111441.

²⁵ J. A. Álvarez-García, J. A. Ortega, L. G. Abril, F. Morente, Trip destination prediction based on past GPS log using a Hidden Markov Model, „Expert Systems with Applications” 2010, t. 37, nr 12, s. 8166–8171, DOI:10.1016/j.eswa.2010.05.070.


²⁶ S. Taguchi, S. Koide, T. Yoshimura, Online map matching with route prediction, „IEEE Transactions on Intelligent Transportation Systems” 2019, t. 20, s. 338–347, DOI:10.1109/TITS.2018.2812147.

Współczesne rozwiązania w dziedzinie predykcji trajektorii coraz szerzej wykorzystują zaawansowane techniki sztucznej inteligencji, które potrafią uczyć się złożonych zależności przestrzenno-czasowych bezpośrednio z danych. Fundamentalną rolę odgrywają tu RNN, w szczególności LSTM (ang. Long Short-Term Memory) oraz GRU (ang. Gated Recurrent Unit), które dzięki swojej architekturze efektywnie przetwarzają dane sekwencyjne i zapamiętują historyczne informacje o trasie pojazdu²⁷. Aby modele mogły lepiej rozumieć kontekst przestrzenny, architektury rekurencyjne są często łączone ze CNN, które mogą służyć do ekstrakcji cech z danych o infrastrukturze drogowej²⁸, lub z GNN, które bezpośrednio modelują topologię sieci drogowej²⁹. Najnowsze badania koncentrują się na zastosowaniu modeli Transformer oraz mechanizmów uwagi, które wykazują skuteczność w kodowaniu złożonych interakcji, kontekstu sytuacyjnego (np. obiekty infrastruktury) oraz długo-terminowych zależności w trasie, co znacząco poprawia precyzję prognoz³⁰.

Unifikacja map-matching'u i predykcji trajektorii pojazdu

W poprzednich rozdziałach dokonano rozłącznej analizy stosowanych technik dla zadań dopasowania do mapy oraz predykcji trajektorii pojazdu. Możliwe jest jednak połączenie obu procesów w jednej architekturze tak, by wzajemnie się uzupełniały, co zobrazowano na rysunku 3.

Rys. 3. Diagram unifikacji map-matching'u i predykcji trajektorii pojazdu.



Źródło: opracowanie własne.

²⁷ H. Jiang, L. Chang, Q. Li, D. Chen, Trajectory prediction of vehicles based on deep learning, „2019 4th International Conference on Intelligent Transportation Engineering (ICITE)” 2019, s. 190–195, DOI:10.1109/ICITE.2019.8880168.

²⁸ Z. Duan, Y. Yang, K. Zhang, Y. Ni, S. Bajgain, Improved deep hybrid networks for urban traffic flow prediction using trajectory data, „IEEE Access” 2018, t. 6, s. 31820–31827, DOI:10.1109/ACCESS.2018.2845863.

²⁹ T. Bogaerts, A. D. Masegosa, J. S. Angarita-Zapata, E. Onieva, P. Hellinckx, A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data, „Transportation Research Part C-emerging Technologies” 2020, t. 112, s. 62–77, DOI:10.1016/j.trc.2020.01.010.

³⁰ M. Kim, B. I. Kwak, J.-U. Hou, T. Kim, Robust long-term vehicle trajectory prediction using link projection and a situation-aware transformer, „Sensors” 2024, t. 24, nr 8, DOI:10.3390/s24082398.

Fundamentem dla takiego systemu jest semantycznie bogata, wektorowa reprezentacja sieci drogowej, uzyskiwana w fazie offline. W tej fazie, GNN jest trenowana na danych topologicznych w celu wygenerowania wektorowych reprezentacji, kodujących złożone właściwości strukturalne każdego segmentu drogi. W fazie online, tak przygotowane reprezentacje są wykorzystywane przez oba moduły. Moduł dopasowania do mapy przyporządkowuje każdą pozycję pojazdu do segmentu drogowego, uwzględniając jednocześnie kontekst sekwencyjny trajektorii oraz właściwości sieci, co pozwala na utworzenie zweryfikowanej historii trasy. Historia ta, w postaci sekwencji wektorów, stanowi dane wejściowe dla modułu predykcji. Kluczowym elementem jest pętla sprzężenia zwrotnego, w której hipoteza predykcyjna jest przekazywana z powrotem do modułu dopasowania, umożliwiając dynamiczną korektę błędów. Ostateczny wynik stanowi zestaw zweryfikowanej przeszłości z modułu dopasowania oraz prognozowanej przyszłości z modułu predykcji.

Podsumowanie

Dynamiczny przyrost wolumenu danych geolokalizacyjnych stwarza znaczące możliwości w zakresie analizy złożonych wzorców. Dostępność wielkoskalowych zbiorów danych jest kluczowa dla efektywnego zastosowania architektur głębokiego uczenia, w szczególności GNN i RNN. Wykazują one wysoką skuteczność w estymacji zależności czasoprzestrzennych oraz topologicznych, co pozwala na przekształcanie surowych strumieni danych w predykcyjne modele zachowań. Zdolność ta stanowi podstawę dla rozwoju zaawansowanych narzędzi, wspierających rozwiązywanie kluczowych problemów w obszarach ITS, rozwoju pojazdów autonomicznych i optymalizacji procesów logistycznych.

Bibliografia

- Álvarez-García, J. A., Ortega, J. A., Abril, L. G., Morente, F., Trip destination prediction based on past GPS log using a Hidden Markov Model, „Expert Systems with Applications” 2010, t. 37, nr 12, DOI:10.1016/j.eswa.2010.05.070.
- Bernstein, D., Kornhauser, A., An introduction to map matching for personal navigation assistants, 1996.
- Bogaerts, T., Masegosa, A. D., Angarita-Zapata, J. S., Onieva, E., Hellinckx, P., A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data, „Transportation Research Part C-emerging Technologies” 2020, t. 112, DOI:10.1016/j.trc.2020.01.010.
- Chawuthai, R., Kawachakul, K., Boonrod, K., Threepak, T., Route prediction from gps trajectory and road data, „2023 15th International Conference on Computer and Automation Engineering (ICCAE)” 2023, DOI:10.1109/ICCAE56788.2023.10111441.
- Chen, W., Li, Z., Yu, M., Chen, Y., Effects of sensor errors on the performance of map matching, „Journal of Navigation” 2005, t. 58, DOI:10.1017/S0373463305003164.
- Davidson, P., Collin, J., Takala, J. H., Application of particle filters to a map-matching algorithm, „Gyroscopy and Navigation” 2011, t. 2, DOI:10.1134/S2075108711040067.
- Duan, Z., Yang, Y., Zhang, K., Ni, Y., Bajgain, S., Improved deep hybrid networks for urban traffic flow prediction using trajectory data, „IEEE Access” 2018, t. 6, DOI:10.1109/ACCESS.2018.2845863.
- Feng, J., Li, Y., Zhao, K., Xu, Z., Xia, T., Zhang, J., Jin, D., Deep learning based map matching with data augmentation, „IEEE Transactions on Mobile Computing” 2022, t. 21, nr 7, DOI:10.1109/TMC.2020.3043500.

- Goh, C. Y., Dauwels, J., Mitrovic, N., Asif, M. T., Oran, A., Jaillet, P., Online map-matching based on Hidden Markov Model for real-time traffic sensing applications, „2012 15th International IEEE Conference on Intelligent Transportation Systems” 2012, DOI:10.1109/ITSC.2012.6338627
- Greenfeld, J. S., Matching gps observations to locations on a digital map, „Transportation research board 81st annual meeting” 2002, t. 22.
- Hu, G., Shao, J., Liu, F., Wang, Y., Shen, H. T., If-matching: Towards accurate map-matching with information fusion, „IEEE Transactions on Knowledge and Data Engineering” 2017, t. 29, DOI:10.1109/TKDE.2016.2617326.
- Hummel, B., Map matching for vehicle guidance, „Dynamic and mobile GIS” 2006.
- Jeong, S., Shin, H., Kim, M.-j., Kang, D., Lee, S.-W., Oh, S., Enhancing LiDAR Mapping with YOLO-Based Potential Dynamic Object Removal in Autonomous Driving, „Sensors (Basel, Switzerland)” 2024, t. 24, nr 23, DOI:10.3390/s24237578.
- Jiang, H., Chang, L., Li, Q., Chen, D., Trajectory prediction of vehicles based on deep learning, „2019 4th International Conference on Intelligent Transportation Engineering (ICITE)” 2019, DOI:10.1109/ICITE.2019.8880168.
- Kempinska, K., Davies, T. O., Shawe-Taylor, J., Probabilistic map-matching using particle filters, „arXiv: Machine Learning” 2016, DOI:10.48550/arXiv.1611.09706.
- Kim, M., Kwak, B. I., Hou, J.-U., Kim, T., Robust long-term vehicle trajectory prediction using link projection and a situation-aware transformer, „Sensors” 2024, t. 24 , nr 8, DOI:10.3390/s24082398.
- Liu, Y., Li, Z., A novel algorithm of low sampling rate gps trajectories on map-matching, „EURASIP Journal on Wireless Communications and Networking” 2017, DOI:10.1145/1653771.1653820.
- Liu, Y., Ge, Q., Luo, W., Huang, Q., Zou, L., Wang, H., Li, X., Liu, C., GraphMM: Graph-based vehicular map matching by leveraging trajectory and road correlations, „IEEE Transactions on Knowledge and Data Engineering” 2024, t. 36, nr 1, DOI: 10.1109/TKDE.2023.3287739.
- Liu, Z., Fang, J., Tong, Y., Xu, M., Deep learning enabled vehicle trajectory map-matching method with advanced spatial-temporal analysis, „IET Intelligent Transport Systems” 2020, t. 14, nr 14, , DOI:10.1049/iet-its.2020.0486.
- Mohanty, A., Gao, G., A survey of machine learning techniques for improving global navigation satellite systems, „EURASIP Journal on Advances in Signal Processing” 2024, DOI:10.48550/arXiv.2406.16873.
- Montenbruck, O., Steigenberger, P., Aicher, M., A long-term broadcast ephemeris model for extended operation of GNSS satellites, „Annual of Navigation” 2021, t. 68, nr 1, DOI:10.1002/navi.404.
- Nassreddine, G., Abdallah, F., Denoeux, T., Map matching algorithm using interval analysis and dempster-shafer theory, „2009 IEEE Intelligent Vehicles Symposium” 2009, DOI:10.1109/IVS.2009.5164328.
- Quddus, M. A., Noland, R. B., Ochieng, W. Y., A high accuracy fuzzy logic based map matching algorithm for road transport, „Journal of Intelligent Transportation Systems” 2006, t. 10, DOI:10.1080/15472450600793560.
- Quddus, M. A., Ochieng, W. Y., Zhao, L., Noland, R. B., A general map matching algorithm for transport telematics applications, „GPS Solutions” 2003, t. 7, DOI:10.1007/s10291-003-0069-z
- Shen, Z., Yang, K., Zhao, X., Zou, J., Du, W., Wu, J., Dmm: A deep reinforcement learning based map matching framework for cellular data, „IEEE Transactions on Knowledge and Data Engineering” 2024, t. 36, nr 10, DOI:10.1109/TKDE.2024.338388.
- Song, H. Y., Lee, J. H., A map matching algorithm based on modified Hidden Markov Model considering time series dependency over larger time span, „Heliyon” 2023, t. 9, nr 11, DOI:10.1016/j.heliyon.2023.e21368.
- Taguchi, S., Koide, S., Yoshimura, T., Online map matching with route prediction, „IEEE Transactions on Intelligent Transportation Systems” 2019, t. 20, DOI:10.1109/TITS.2018.2812147.

- Wu, H., Chen, Z., Sun, W., Zheng, B., Wang, W., Modeling trajectories with recurrent neural networks, „Proceedings of the 26th International Joint Conference on Artificial Intelligence” 2017, DOI:10.24963/ijcai.2017/430.
- Xiong, Z., Li, B., Liu, D., Map-matching using Hidden Markov Model and path choice preferences under sparse trajectory, „Sustainability” 2021, t. 13, nr 22, DOI:10.3390/su132212820.
- Zhang, Y., Gao, Y., A fuzzy logic map matching algorithm, „2008 Fifth International Conference on Fuzzy Systems and Knowledge Discovery” 2008, t. 3, DOI:10.1109/FSKD.2008.234.
- Zhilinskiy, V., Gagarina, L., Ishkova, T., Petrov, E., Petrova, A., Software package for solving navigation problem using systematic instrumental error correction, 2019, DOI:10.1109/EIConRus.2019.8657157.