

APLIKACJA DO ROZPOZNAWANIA PIONOWYCH ZNAKÓW DROGOWYCH

Szymon Grochowski¹, Sebastian Kula^{1,2}

¹Uniwersytet Kazimierza Wielkiego
Wydział Informatyki

ul. Kopernika 1, 85-074 Bydgoszcz

²Zachodniopomorski Uniwersytet Technologiczny
Wydział Telekomunikacji, Informatyki i Elektrotechniki
ul. Żołnierska 49, 71-210 Szczecin

e-mail: szymon.grochowski@student.ukw.edu.pl

Streszczenie: W pracy przedstawiono aplikację do rozpoznawania pionowych znaków drogowych z użyciem modelu sztucznej inteligencji, zaprojektowaną w celu poprawy bezpieczeństwa ruchu drogowego. Model został przetrenowany na przygotowanym zbiorze danych obejmującym zdwersyfikowane obrazy, wzbogacone technikami augmentacji. Aplikacja umożliwia wykrywanie znaków drogowych z kamery internetowej oraz nagrań wideo. Model sztucznej inteligencji wykazuje potencjał do zastosowań w systemach wsparcia kierowców i technologii autonomicznych pojazdów.

Słowa kluczowe: sztuczna inteligencja, znaki drogowe, wizja komputerowa, uczenie maszynowe, detekcja obiektów.

APPLICATION FOR RECOGNIZING VERTICAL TRAFFIC SIGNS

Abstarct: This paper presents an application for recognizing vertical traffic signs using an artificial intelligence model, designed to enhance road safety. The model was trained on a prepared dataset comprising diversified images, enriched with augmentation techniques. The application enables the detection of traffic signs from webcam feeds and video recordings. The artificial intelligence model shows potential for use in driver assistance systems and autonomous vehicle technologies.

Keywords: artificial intelligence, traffic signs, computer vision, machine learning, object detection.

1. Wstęp

Współczesne systemy rozpoznawania znaków drogowych odgrywają kluczową rolę w zwiększaniu bezpieczeństwa ruchu drogowego oraz wspieraniu systemów autonomicznego prowadzenia pojazdów. Pomimo rozwoju technologii, nadal występują przypadki błędnej interpretacji lub całkowitego braku detekcji znaków drogowych, co stwarza potencjalne zagrożenie na drogach. Rozwiązaniem tych problemów są zaawansowane algorytmy sztucznej inteligencji, które umożliwiają efektywne i dokładne rozpoznawanie elementów otoczenia, takich jak znaki informacyjne, ostrzegawcze czy nakazu, w czasie rzeczywistym [1-3].

Znaki drogowe, jako istotny element infrastruktury drogowej, pełnią funkcję kluczowego nośnika informacji dla kierowców. Ich błędna interpretacja lub brak zauważenia może prowadzić do niebezpiecznych sytuacji na drodze. W tym kontekście technologie

sztucznej inteligencji, w szczególności konwolucyjne sieci neuronowe, stały się fundamentem w projektowaniu systemów automatycznego rozpoznawania znaków. Zaprojektowane są, by automatycznie uczyły się cechy przestrzenne i czasowe danych, stosując filtry konwolucyjne na wejściowych obrazach [4]. Choć sieci te cechuje wysoka skuteczność, ich dokładność może być ograniczona przez zmienne warunki, takie jak różne kąty widzenia, oświetlenie czy orientacja znaków. W odpowiedzi na te wyzwania opracowano zaawansowane modele, które łączą szybkość działania z wysoką precyzją detekcji.


Jednym z takich rozwiązań jest model YOLO (You Only Look Once), który wykorzystuje potencjał głębokiego uczenia do analizy obrazów w czasie rzeczywistym.

W niniejszej pracy zastosowano najnowszą wersję tego modelu – YOLOv8, która jest zbudowana na najnowocześniejszych postęпах w dziedzinach głębokiego uczenia i wizji komputerowej, oferując niespotykaną wydajność w kwestii prędkości i dokładności [5]. Zamiast tworzenia modelu od

podstaw, zdecydowano się na przetrenowanie gotowego modelu YOLOv8, co pozwoliło zoptymalizować proces detekcji przy ograniczonych zasobach obliczeniowych. Przedstawione badania koncentrują się na detekcji wybranych pionowych znaków drogowych, takich jak znaki informacyjne, ostrzegawcze i nakazu, z wykorzystaniem obrazów z kamer oraz nagrań wideo. Proces trenowania modelu został oparty na starannie przygotowanym zbiorze danych, uwzględniającym różnorodność warunków drogowych i środowiskowych. Ponadto zaprojektowano aplikację umożliwiającą rozpoznawanie znaków drogowych zarówno w czasie rzeczywistym, jak i w trybie analizy nagrań, co otwiera nowe perspektywy dla rozwoju technologii wspomagających bezpieczeństwo na drogach.

2. Metody detekcji znaków


Do detekcji znaków drogowych wykorzystano model YOLOv8, będący najnowszą wersją algorytmu YOLO (You Only Look Once). YOLO to jednoprzebiegowy algorytm detekcji obiektów, który analizuje obrazy przy użyciu pojedynczej sieci neuronowej. Sieć YOLO widzi cały obraz w czasie treningu i testów niejawnie koduje informacje kontekstowe o klasach, oraz ich wyglądzie [6]. Na Rysunku 1 przedstawiono proces jednolitej detekcji obiektów przez YOLO, jest to jednoczesnej detekcji i klasyfikacji obiektów z użyciem pojedynczego modelu zamiast podziału na osobne etapy.



Rys. 1. Jednolita detekcja YOLO
(źródło: <https://arxiv.org/pdf/1506.02640.pdf>)

Chociaż algorytm charakteryzuje się wysoką prędkością działania, dokładność lokalizacji obiektów może być niższa w przypadku małych elementów w porównaniu do detektorów dwuetapowych. Na rysunku 1 przedstawiono bazową strukturę YOLOv8, która jest ulepszoną wersją sieci Darknet, zapewniająca wysoką dokładność i

optymalizację obliczeniową. Darknet to środowisko open-source do tworzenia sieci neuronowych napisane w językach C i CUDA. Jest szybkie, łatwe w instalacji i obsługuje obliczenia zarówno na procesorze (CPU), jak i na karcie graficznej (GPU) [7]. Na rysunku 2 przedstawiono szkielet YOLOv8.



Rys. 2. Struktura YOLO

(źródło: <https://www.mathworks.com/videos/introduction-to-deep-learning-what-are-convolutional-neural-networks--1489512765771.html>)

YOLOv8 wprowadza nowe funkcje i optymalizacje, dzięki czemu jest idealnym wyborem dla różnych zadań wykrywania obiektów w szerokim zakresie aplikacji [5].

Do przygotowania danych wykorzystano platformę Roboflow, gdzie obrazy zostały ręcznie etykietowane, przetwarzane do formatu 640×640 pikseli i wzbogacone technikami augmentacji, takimi jak obracanie o 15° czy zmiana jasności o $\pm 36\%$.

3. Wyniki testów funkcjonalności

Podczas testów funkcjonalności aplikacji, część odpowiedzialna za detekcję z kamerki była sprawdzana poprzez prezentację znaków drogowych w formie

wydruków na kartkach A4 oraz zdjęć z Google Images wyświetlanych na ekranie telefonu komórkowego. Średnia pewność detekcji dla poprawnie rozpoznanych znaków wynosiła od 60% do ponad 80%. Dla każdego wykrytego znaku aplikacja poprawnie rysowała ramkę detekcji oraz wyświetlała podpis wraz z zaokrąglonym do jednego miejsca po przecinku prawdopodobieństwem.

Testy wykazały, że aplikacja skutecznie rozpoznaje znaki drogowe w różnych warunkach, jednak nie była wolna od błędów. W niektórych przypadkach model YOLOv8 generował fałszywe pozytywne detekcje, np. rysując ramki wokół obiektów, które nie były znakami drogowymi. Tego typu błędy wynikały z podobieństwa kształtów lub kolorów niektórych obiektów do cech typowych dla znaków drogowych.

Podczas testów detekcji z nagrań wideo aplikacja poprawnie lokalizowała i klasyfikowała znaki drogowe w analizowanych plikach .mp4. Detekcja była stabilna i osiągała podobne wyniki w zakresie pewności, co w przypadku kamerki. Jednakże ograniczenie do sztywno ustalonej ścieżki do pliku w kodzie źródłowym uniemożliwiało dynamiczną zmianę nagrania do analizy, co może być przeszkodą w szerszym zastosowaniu tej funkcjonalności.

4. Podsumowanie i wniosek

Podczas testów aplikacji część odpowiedzialna za detekcję w czasie rzeczywistym została przetestowana przy użyciu wydruków znaków drogowych na kartkach formatu A4 oraz zdjęć znaków wyświetlanych na ekranie telefonu komórkowego (Google Images). Wyniki wykazały, że średnia pewność detekcji dla poprawnie rozpoznanych znaków wynosiła od 60% do ponad 80%. Dla każdego wykrytego znaku aplikacja poprawnie rysowała ramkę detekcji oraz wyświetlała nazwę znaku wraz z zaokrąglonym do jednego miejsca po przecinku prawdopodobieństwem pewności.

Podczas testów aplikacji część odpowiedzialna za detekcję w czasie rzeczywistym została przetestowana przy użyciu wydruków znaków drogowych na kartkach formatu A4 oraz zdjęć znaków wyświetlanych na ekranie telefonu komórkowego (Google Images). Wyniki wykazały, że średnia pewność detekcji dla poprawnie rozpoznanych znaków wynosiła od 60% do ponad 80%. Dla każdego wykrytego znaku aplikacja poprawnie rysowała ramkę detekcji oraz wyświetlała nazwę znaku wraz z

zaokrąglonym do jednego miejsca po przecinku prawdopodobieństwem pewności.

Pomimo wysokiej skuteczności w większości przypadków, odnotowano błędy w postaci fałszywych pozytywnych detekcji. Zdarzały się sytuacje, w których model YOLOv8 klasyfikował obiekty o podobnych cechach (np. kolorach lub kształtach) jako znaki drogowe, co wskazuje na potrzebę dalszej optymalizacji modelu, szczególnie w zakresie redukcji fałszywych pozytywnych.

Część aplikacji odpowiedzialna za analizę nagrań wideo również wykazała się wysoką skutecznością. Testy przeprowadzono na plikach .mp4, a detekcja znaków była stabilna, osiągając podobne wyniki w zakresie pewności, jak w przypadku detekcji w czasie rzeczywistym. Model skutecznie lokalizował i klasyfikował znaki drogowe, co potwierdza jego przydatność w analizie materiałów wideo. Jednak funkcjonalność ta posiada ograniczenie w postaci braku możliwości dynamicznego wyboru pliku wideo do analizy. Ścieżka pliku jest zdefiniowana w kodzie źródłowym, co może utrudniać jej praktyczne wykorzystanie w różnych scenariuszach.

Wyniki przeprowadzonych testów potwierdzają skuteczność modelu YOLOv8 w rozpoznawaniu znaków drogowych, zarówno w czasie rzeczywistym, jak i w analizie nagrań wideo. Model wykazuje większą stabilność w rozpoznawaniu znaków w warunkach statycznych, takich jak wydruki lub wideo w kontrolowanych warunkach, niż w dynamicznych scenariuszach, w których występują zmienne oświetlenie, nietypowe kąty widzenia lub przeszkody w polu widzenia kamerki.

Aplikacja, mimo odnotowanych ograniczeń, stanowi solidne narzędzie do testowania i dalszego rozwoju technologii rozpoznawania znaków drogowych. Dalsza optymalizacja modelu, rozszerzenie zbioru danych treningowych oraz wprowadzenie mechanizmów zmniejszających liczbę fałszywych pozytywnych może zwiększyć skuteczność i funkcjonalność aplikacji. Możliwość dynamicznego wyboru plików wideo i dodatkowe dostosowanie interfejsu aplikacji są kluczowymi obszarami rozwoju, które mogłyby przyczynić się do jeszcze szerszego zastosowania tego narzędzia w systemach wspierających bezpieczeństwo ruchu drogowego.

Literatura

1. Jan Matuszewski, "System inteligentny rozpoznawania znaków drogowych," Wojskowa Akademia Techniczna, Wydział Elektroniki, Instytut Radioelektroniki, DOI:10.15199/48.2016.01.10.

2. Salah Zaki, P., William, M. M., Soliman, B. K., Alexsan, K. G., Khalil, K., El-Moursy, M., "Traffic Signs Detection and Recognition System using Deep Learning."
 3. A. Radha Rani, Y. Anusha, S.K. Cherishama, S. Vijaya Laxmi, Traffic sign detection and recognition using deep learning-based approach with haze removal for autonomous vehicle navigation, e-Prime - Advances in Electrical Engineering, Electronics and Energy, Volume 7, 2024, 100442, <https://doi.org/10.1016/j.prime.2024.100442>.
 4. Mrinal Kanti Bhowmik, Computer Vision Object Detection In Adversarial Vision, CRC Press, 2023
 5. Dokumentacja YOLOv8, <https://docs.ultralytics.com>
 6. Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi, You Only Look
 7. Darknet: Open Source Neural Networks in C <https://pjreddie.com/darknet/>
- Rysunek 1. Jednolita detekcja YOLO (źródło: <https://arxiv.org/pdf/1506.02640.pdf>)
- Rysunek 2. Architektura konwolucyjnej sieci neuronowej (źródło: <https://www.mathworks.com/videos/introduction-to-deep-learning-what-are-convolutional-neural-networks--1489512765771.html>)