PRZEGLĄD ELEKTROTECHNICZNY

OPEN ACCESS

Julian BALCEREK[1], Paweł PAWŁOWSKI[2], Tymon STANKIEWICZ[3], Eryk VYKYSALÝ[4]

ORCID: [1]0000-0003-1317-9866, [2]0000-0001-5373-5148

DOI: 10.15199/48.2025.11.21

Automatyczne rozpoznawanie powalonych drzew na drogach

Automatic recognition of fallen trees on roads

[1] dr inż. Julian Balcerek, Politechnika Poznańska, Wydział Automatyki, Robotyki i Elektrotechniki, Instytut Automatyki i Robotyki, ul. Piotrowo 3a, 61-138 Poznań, Polska, e-mail: julian.balcerek@put.poznan.pl

[2] dr inż. Paweł Pawłowski, Politechnika Poznańska, Wydział Automatyki, Robotyki i Elektrotechniki, Instytut Automatyki i Robotyki, ul. Piotrowo 3a, 61-138 Poznań, Polska, e-mail: pawel.pawlowski@put.poznan.pl

[3] inż. Tymon Stankiewicz, Politechnika Poznańska, Wydział Automatyki, Robotyki i Elektrotechniki, ul. Piotrowo 3a, 61-138 Poznań, Polska, e-mail: tymon.stankiewicz@student.put.poznan.pl

[4] inż. Eryk Vykysalý, Politechnika Poznańska, Wydział Automatyki, Robotyki i Elektrotechniki, ul. Piotrowo 3a, 61-138 Poznań, Polska, e-mail: eryk.vykysaly@student.put.poznan.pl

Adres do korespondencji: julian.balcerek@put.poznan.pl

Streszczenie: W niniejszym artykule zaprezentowano system do automatycznego rozpoznawania powalonych drzew na drogach z perspektywy pojazdu. System dokonuje analizy obrazów za pomocą sztucznych sieci neuronowych. Do przeprowadzenia testów skuteczności rozpoznawania przygotowano bazę obrazów, z uwzględnieniem przyjętych kryteriów doboru, klatek referencyjnych, różnych rodzajów anotacji i augmentacji danych. Dla sieci wytrenowanych na większych obszarach zaznaczeń obiektów osiągnięto ponad 90-procentową dokładność rozpoznawania.

Słowa kluczowe: analiza obrazów, detekcja obiektów, rozpoznawanie powalonych drzew, baza obrazów, sztuczne sieci neuronowe

Abstract: This article presents a system for automatic recognition of fallen trees on roads from a vehicle perspective. The system uses artificial neural networks for image analysis. A database of images was prepared to carry out the recognition tests, taking into account the adopted selection criteria, reference frames, various types of data annotation and augmentation. For networks trained on larger areas of object selection, over 90% recognition accuracy was achieved.

Keywords: image analysis, object detection, fallen tree recognition, image database, artificial neural networks

Wstęp

W pojazdach stosowane są coraz bardziej zaawansowane systemy wspomagania pracy kierowców [1]. Mogą one np. ułatwiać parkowanie, informować o zjechaniu z pasa ruchu, czy też przeprowadzać proces automatycznego hamowania w sytuacjach awaryjnych. Niektóre z nich mają możliwość ostrzeżenia kierowcy o przeszkodzie, aby móc w bezpieczny sposób ją ominąć. Celem takich rozwiązań jest redukcja ryzyka wypadków na drogach oraz poprawa komfortu i bezpieczeństwa kierowców.

Do pozyskiwania danych w pojazdach wykorzystuje się różne czujniki, takie jak radary, lidary, czy też sensory wizyjne. Systemy wizyjne mogą używać kamer wbudowanych w pojeździe lub wideorejestratorów w postaci urządzeń akcesoryjnych. Umożliwiają one rozpoznawanie obiektów potencjalnie stanowiących zagrożenie dla poruszającego się pojazdu. Zagrożenie mogą stanowić np. inne pojazdy, zwierzęta, kamienie, lód lub fragmenty innych pojazdów, takie jak np. odpadające koła [2−5].

Nieodłącznym elementem krajobrazu są drzewa, które mają ewidentnie pozytywny wpływ na środowisko [6]. Średnia lesistość w Polsce w 2023 roku wynosiła prawie 30%, a w przypadku województwa lubuskiego osiągnęła nawet ponad 49% [7]. Liczba wypadków najechania na drzewo wynosiła 1025, czyli prawie 5% wszystkich wypadków drogowych [8]. Cechowała je wysoka śmiertelność, wynosząca ponad 16% spośród wszystkich ofiar wypadków drogowych.

Zagrożenie mogą stanowić drzewa, które po powaleniu np. pod wpływem zjawisk atmosferycznych, chorób, czy też starzenia znalazły się w torze ruchu pojazdu. Ponadto, dla dominujących gatunków drzew w Europie Środkowej, gęstość drewna od 1900 roku zmniejszyła się o 8−12% [9], co może powodować większą podatność drzew na złamania.

Do rozpoznawania powalonych drzew mogą służyć dane uzyskane za pomocą tzw. lotniczego skaningu laserowego (z ang. Airborne Laser Scanning, ALS) [10−12]. Można go wykorzystać, wraz z danymi o prędkości i kierunku wiatru do wczesnej detekcji drzew narażonych na przewrócenie się, szczególnie tych znajdujących się przy infrastrukturze drogowej [13]. Korzysta się również z bezzałogowych statków powietrznych (z ang. Unmanned Aerial Vehicles, UAV), potocznie zwanych dronami, oraz czujników wizyjnych, w połączeniu z zaawansowanymi algorytmami uczenia maszynowego [14−16]. Połączenie obu tych systemów zostało już użyte do ogólnego mapowania lasów [17].

Powszechnie dostępne wideorejestratory, obok kamer monitoringu, ze względu na dostępność danych, uniwersalność związaną z różnymi parametrami urządzeń i możliwość zastosowania jako akcesorium np. w starszych pojazdach, mogą stanowić źródło informacji dla badań dotyczących automatycznego rozpoznawania powalonych drzew. Docelowo właściwe rozpoznanie przez system wizyjny drzewa lub jego fragmentu znajdującego się na drodze mogłoby odbywać się przy różnych prędkościach i jest istotne z punktu widzenia bezpieczeństwa. Przy niskich prędkościach, po wyhamowaniu na podstawie wskazań np. radaru, mogłoby służyć potwierdzeniu i, na tej podstawie, np. dalszemu poinformowaniu innych użytkowników ruchu za pomocą dostępnych systemów komunikacji. Przy wysokich prędkościach mogłoby z kolei inicjować rozpoczęcie awaryjnego hamowania, próbę ominięcia przeszkody oraz wstępne przygotowanie systemów bezpieczeństwa do ochrony w czasie wypadku.

W niniejszej pracy zaproponowano i przetestowano możliwości automatycznego rozpoznawania powalonych drzew na drogach na podstawie analizy obrazów. Do rozpoznawania wykorzystano sztuczne sieci neuronowe, uwzględniając różne rodzaje anotacji i augmentacji danych. Testy przeprowadzono na specjalnie przygotowanej bazie.

Baza obrazów powalonych drzew

Wykonanie i przetestowanie systemu do rozpoznawania powalonych drzew wymagało przygotowania bazy obrazów. Do zbierania obrazów wykorzystano różne źródła internetowe, w tym związane z miejscowymi strażami pożarnymi. Obrazy stanowiły wybrane, pojedyncze ujęcia lub były pozyskane z materiałów filmowych. Aby obraz mógł zostać uwzględniony w bazie, musiał spełniać ustalone kryteria, które zostały podzielone na podstawowe oraz dodatkowe.

Do kryteriów podstawowych należał warunek, aby obraz przedstawiał powalone drzewo już leżące na drodze lub ujęcie drzewa w końcowym etapie jego upadku na drogę. Wymagane było również, aby ujęcie zostało wykonane z perspektywy wideorejestratora samochodowego lub zbliżonej do jego poziomu. Ujęcie musiało przedstawiać widoczny pień drzewa, który nie był w znacznym stopniu zasłonięty. Zarejestrowane drzewa musiały charakteryzować się cechami gatunków występujących w Europie Środkowo-Wschodniej.

Ze względu na dużą różnorodność i nieregularność drzew, wiele obrazów spełniających tylko podstawowe kryteria mogłoby obniżać wydajność wytrenowanych modeli, stąd uwzględniono również kryteria dodatkowe. Należały do nich: tło zdjęcia, kształt drzewa, odległość drzewa od obiektywu kamery, kąt położenia drzewa względem drogi, jakość obrazu oraz kontrast drzewa względem otoczenia.

Kryterium tła zdjęcia związane było z potencjalnie negatywnym wpływem na szkolenie modelu obiektów innych niż wykrywane drzewa, np. samochodów lub wycieraczek, mogących znaleźć się w obszarze anotacji oraz kawałków drewna, niespójnych z podstawową strukturą drzewa. Zaznaczenie obiektów imitujących drzewa mogłoby prowadzić do zwiększenia liczby fałszywych wykryć, a większych, leżących osobno, fragmentów drzewa (mniejszych kawałków gałęzi lub części konarów) mogłoby wprowadzić dodatkowy szum. Z kolei ich pominięcie mogłoby obniżyć zdolność do wykonywania prawidłowych wykryć. Wyselekcjonowano zatem ujęcia z minimalną ilością odłamanych fragmentów, bez dodatkowych obiektów w obrębie zaznaczonego drzewa.

Kryterium kształtu drzewa wprowadzono ze względu na potencjalny jego wpływ na proces rozpoznawania. Wiele drzew charakteryzuje się podłużnymi pniami, które stanowią ich znaczną część. Niektóre obrazy przedstawiały pnie o nieregularnych kształtach, które trudno było jednoznacznie anotować stosując prostokątne zaznaczenia i takich obrazów nie uwzględniono w bazie.

Kryterium odległości drzewa od obiektywu kamery zagwarantowało akceptowalną widoczność cech charakterystycznych. Obiekty znajdujące się zbyt daleko byłyby mało widoczne, a znajdujące się zbyt blisko obiektywu mogłyby zajmować zbyt dużą część kadru.

Kryterium kąta położenia drzewa względem drogi zakładało, że drzewo leżało w poprzek drogi w pozycji poziomej. W innych przypadkach drzewo mogło upaść w orientacji bardziej wzdłuż drogi lub, w trakcie upadku, mogło oprzeć się o inny obiekt, przyjmując pozycję zbliżoną do pionowej.

Kryterium jakości eliminowało obrazy o zbyt niskiej jakości, które nie zawierały cech, umożliwiających poprawne rozpoznawanie przez automatyczny system i wspomagających model podczas szkolenia.

Kryterium kontrastu wymagało odpowiedniego kontrastu pomiędzy powalonym drzewem a tłem. Odrzucane były ujęcia wykonane w warunkach zimowych, gdzie drzewo i droga były pokryte śniegiem, a także ujęcia z niewłaściwym oświetleniem.

Dodatkowo, do bazy dodano obrazy referencyjne, które nie zawierały powalonych drzew. Ich celem było zwiększenie odporności sieci neuronowej na fałszywe wykrycia podczas szkolenia, a także mogły służyć jako dane kontrolne w trakcie testowania modelu sieci.

Spośród wielu tysięcy ocenianych obrazów, liczba dostępnych obrazów w pełni odzwierciedlających przedstawione kryteria, była bardzo ograniczona. Z tego powodu, na podstawie wiedzy oraz doświadczenia uzyskanych z eksperymentów roboczych, utworzona baza zawierała niewielką część obrazów o pojedynczych, niespełnionych kryteriach. Czynność ta była konieczna, ponieważ zbyt niska liczba liczebność bazy obrazów mogła mieć większy wpływ na wydajność modelu niż wprowadzenie do bazy niewielkiej liczby obrazów różnorodnych. Obrazy te, w przypadku dostępności większej ilości zdjęć i nagrań wideo z powalonymi drzewami, zostałyby w pierwszej kolejności odrzucone.

Na ostateczną zawartość bazy składało się 410 różnych oryginalnych obrazów źródłowych, co, w przypadku uczenia dużych sieci jest wielkością niewystarczającą. Z tego powodu, zastosowane zostały techniki dodatkowe, opisane poniżej.

Anotacja obszarów powalonych drzew wymagała określenia i przestrzegania ustalonych zasad, aby konsekwentnie wybierać zaznaczenia obiektów, z korzyścią dla uczenia sieci. Głównym problemem była duża różnorodność drzew na obrazach, które były mało widoczne lub trudne do precyzyjnego zaznaczenia, co niejednokrotnie wymuszało wybór pomiędzy zawarciem w anotacji niepożądanych obiektów, a niezaznaczeniem części drzewa. Jako rozwiązanie utworzono dwie bazy opracowane z użyciem dwóch, wyraźnie różniących się, wariantów anotacji. Zasadniczą różnicą pomiędzy nimi była powierzchnia zaznaczeń.

Wariant pierwszy, o mniejszej powierzchni zaznaczenia, skupiał się na zaznaczeniu pnia oraz najbardziej widocznych konarów. Niepożądane było zaznaczanie tła lub innych obiektów, częściowo zasłaniających drzewo. W takich przypadkach, drzewo było czasami dzielone na dwie lub więcej części o kształcie prostokątnym. Uwzględniano głównie pień, a także grube, wyraźnie widoczne gałęzie. Tym samym skupiono się na charakterystycznych cechach pnia, ograniczając potencjalne artefakty otoczenia oraz mniej regularne fragmenty drzew (na przykład liści) i zaznaczając jedynie największe oraz najbardziej kontrastowe fragmenty drzew. Podejście to jednak mogło zmniejszać ilość cech charakterystycznych, określających obiekt.

Drugi wariant zaznaczeń, o większej powierzchni, obejmującej pień, konary oraz grubsze gałęzie, skupiał się na konsekwentnym zaznaczaniu drzew w obszarach o poziomych, prostokątnych kształtach. Miało to na celu takie szkolenie modeli, aby wykrywane były podłużne poziome obiekty o cechach charakteryzujących drzewa. To podejście dopuszczało okazjonalne występowanie elementów innych niż drzewa w obrębie obszaru anotacji, w celu zachowania spójności kształtu oznaczeń, jednak duża część obrazów z niepożądanymi obiektami w tle była odrzucana.

Konary stanowią dużą część drzewa, zwiększając liczbę charakterystycznych cech, a ich obecność w obszarze anotacji mogłaby poprawić skuteczność modelu. Z drugiej strony, ze względu na swoją bardziej rozbudowaną strukturę oraz dużą różnorodność zależną głównie od gatunku, a także możliwość występowania małych gałęzi i liści o zróżnicowanych kolorach, mogłyby wprowadzać dodatkowy szum w zaznaczeniu. Jednakże, dla większej ilości danych, mogłyby poprawić skuteczność rozpoznawania.

Dodatkowo, utworzono zbiór testowy, w którym zaznaczenia obiektów nie były zależne od reguł dotyczących tylko mniejszych bądź tylko większych zaznaczeń. Kierowano się intuicyjnym zaznaczaniem obszarów, symulując podejście podmiotu niezależnego, nieposiadającego wiedzy na temat pozostałych podejść.

Opisane podejścia, charakteryzujące się określonymi zaletami i wadami, umożliwiły przygotowanie bazy w dwóch wariantach zaznaczeń (mniejsze i większe) dotyczących treningu, walidacji oraz testu, a także w wariancie pośrednim dotyczącym tylko testu. Pozwoliło to na porównanie wydajności rozpoznawania, zależnie od obranej strategii zaznaczania powalonych drzew.

Aby zwiększyć zdolności generalizacyjne modelu poprzez zwiększenie liczby i różnorodności klatek treningowych za pomocą zmodyfikowanych kopii obrazów źródłowych [18], zastosowano wybrane techniki augmentacji. Dla detekcji, w odróżnieniu od samej klasyfikacji, w przypadku zastosowania przekształceń geometrycznych, należy liczyć się z komplikacją zaznaczeń obiektów [19]. Aby tego uniknąć, zastosowano dwa rodzaje augmentacji: nałożenie szumu na 0,5% pikseli oraz zmianę ekspozycji w samym obszarze anotacji.

Dodanie szumu do obrazu zwiększa różnorodność zdjęć treningowych, przy okazji zbytnio nie wpływając na wygląd obiektu. Niewielki procent zaszumionych pikseli (0,5%) zapewnia, że obiekty pozostają w dużym stopniu nienaruszone, natomiast zostaje wprowadzona różnorodność, która może poprawić działanie modelu sieci. Szum może być wprowadzany również na zdjęciach niezawierających zaznaczeń, tj. pustych. Samo wprowadzenie szumu jako typu augmentacji obrazów w zbiorze treningowym poparte jest również faktem, że szum jest często występującym zjawiskiem w sensorach wizyjnych, szczególnie w trudnych warunkach oświetleniowych.

Za pomocą ograniczenia modyfikacji obrazu jedynie do samego zaznaczenia, model ma możliwość lepszego skupienia się na powalonym drzewie. Zmiana ekspozycji samego obszaru zaznaczenia pozwala na zasymulowanie problemów występujących podczas detekcji w warunkach rzeczywistych, takich jak np. wpływ świateł samochodowych na wygląd powalonego drzewa. Zastosowano ekspozycję zaznaczenia zmienioną o 10%.

Korzystając z wymienionych rodzajów augmentacji, utworzone zostały cztery zestawy bazy obrazów, a każdy z nich w mniejszym i większym wariancie anotacji (tabela 1):

- bez augmentacji – zestaw 1,
- z augmentacją ekspozycji zaznaczenia – zestaw 2,
- z augmentacją szumem – zestaw 3,
- z augmentacją ekspozycji i szumem – zestaw 4.

Obrazy podzielono na rozłączne zbiory: treningowy, walidacyjny i testowy. Zbiory były rozłączne również ze względu na pochodzenie obrazów z nagrań wideo. Z kolei każdy wariant danego zbioru posiadał te same obrazy, tzn. np. zbiór testowy za każdym składał się z tych samych obrazów źródłowych. Dodatkowy zbiór testowy z pośrednim zaznaczeniem zawierał również 30 obrazów i obiektów.

Architektura sztucznych sieci neuronowych

W ramach opracowanego systemu do automatycznego rozpoznawania powalonych drzew, przygotowane zostało odpowiednie oprogramowanie.

Trening modeli do automatycznego rozpoznawania drzew przeprowadzono przy pomocy usługi Google Colaboratory [20], umożliwiającej kompilację kodu w chmurze obliczeniowej i zapewniającej dostęp do wydajnych urządzeń obliczeniowych. Wykorzystano kartę graficzną ”NVIDIA A100 Tensor Core GPU”, zoptymalizowaną do zastosowań związanych z tworzeniem modeli sztucznych sieci neuronowych [21].

Trenowano modele w architekturze YOLO w wersji 8 [22]. Dla systemu, który miałby działać w rzeczywistych warunkach ruchu drogowego, istotna byłaby nie tylko dokładność, ale również czas detekcji. Jednakże w przygotowywanym systemie skupiono się przede wszystkim na dokładności detekcji, mając na uwadze niełatwe zagadnienie rozpoznawania powalonych drzew, ze względu na m.in. problematykę odpowiedniego zaznaczenia, nie najlepszą jakość nagrań z wideorejestratorów, ograniczoną liczbą dostępnych obrazów i zaznaczonych obiektów oraz przewidywany rozwój platform sprzętowych i ich mocy obliczeniowych. Z tych powodów wykorzystany został największy i najdokładniejszy model YOLOv8x [23].

Podczas treningu i walidacji modelu YOLO, zastosowano wybrane wartości różnych parametrów sieci, odpowiednio dobrane na podstawie wstępnych eksperymentów i dokumentacji [23]. Wartość parametru ”epochs”, określającą pełną liczbę epok treningu, ustawiono na 300. Wartość parametru ”patience” ustawiono na 60 epok. Jeżeli model nie wykazywał poprawy przez określoną liczbę epok, trening był zatrzymany, co ograniczało zużycie zasobów obliczeniowych i pomagało w uniknięciu efektu tzw. ”przeuczenia”, czyli

Tabela 1. Liczba obrazów i obiektów w poszczególnych zestawach obrazów dla mniejszych i większych zaznaczeń

zaznaczenie	zestaw	obrazy z powalonymi drzewami			obrazy referencyjne			obiekty			
		trening	walidacja /test	suma	trening	walidacja /test	suma	trening	walidacja	test	suma
mniejsze	1	260	30	320	30	30	90	310	33	30	373
	2	520	30	580	30	30	90	620	33	30	683
	3	520	30	580	60	30	120	620	33	30	683
	4	780	30	840	90	30	150	930	33	30	993
większe	1	260	30	320	30	30	90	302	32	30	364
	2	520	30	580	30	30	90	604	32	30	666
	3	520	30	580	60	30	120	604	32	30	666
	4	780	30	840	90	30	150	906	32	30	968

sytuacji, w której model za bardzo dopasowałby się do danych treningowych i traciłby umiejętności generalizujące. Parametr ”single cls” ustawiono na wartość ”True”, co oznaczało wymuszenie klasyfikacji binarnej podczas działania modelu ze względu na występowanie tylko jednej pozytywnej klasy obiektu, tj. powalonego drzewa. Parametr ”batch size” odpowiadał liczbie próbek (punktów danych), które sieć neuronowa przetwarzała podczas jednej iteracji. Po każdej iteracji następowała aktualizacja wag modelu. Pozostawiono domyślną wartość tego parametru równą 16. Wartość parametru ”imgsz” pozostawiono domyślnie ustawioną na ”640”, co oznaczało rozdzielczość obrazów równą 640 na 640 pikseli. Wszystkie obrazy z bazy przed treningiem zostały przeskalowane do tego rozmiaru. Generalnie, większe obrazy wejściowe mogłyby zwiększyć dokładność detekcji, ale kosztem większych wymagań sprzętowych. Pozostałe parametry konfiguracji pozostawiono na wartościach bazowych.

Przeprowadzono 8 treningów, tj. dla każdej z 2 anotacji dla 4 zestawów związanych z augmentacją. Przebieg procesu treningu i walidacji na przykładzie modelu z dużymi zaznaczeniami i nałożonym szumem przedstawiono na rysunku 1. Wykresy wygenerowane przez sieć YOLOv8x [23] przedstawiają funkcje strat dla treningu i walidacji. Wskazują one na poprawny przebieg nauczania, z malejącymi funkcjami strat, bez widocznego efektu tzw. ”przeuczenia”.

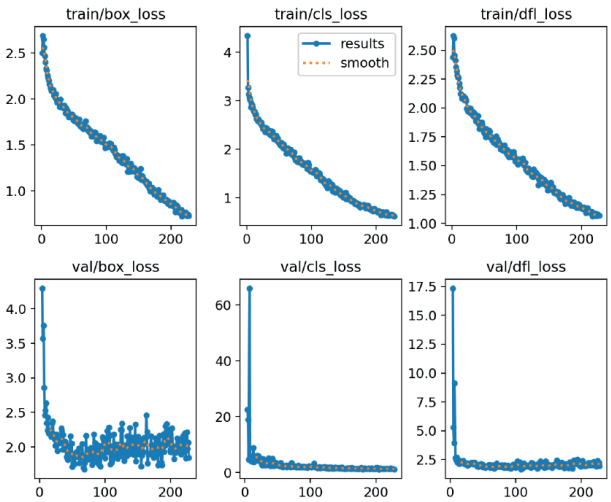

Rys. 1. Przebieg procesu treningu i walidacji na przykładzie modelu z dużymi zaznaczeniami i z nałożonym szumem; wykresy wygenerowane przez sieć YOLOv8x [23]

Testy skuteczności przeprowadzono na komputerze przenośnym HP Pavilion Gaming 15 z systemem operacyjnym Windows 11 Home, procesorem AMD Ryzen 5 3550H 2.10 GHz i 16 GB pamięci RAM. Wykorzystano dedykowaną kartę graficzną NVIDIA GeForce GTX 1650 z architekturą CUDA (z ang. Compute Unified Device Architecture). Dla wytrenowanych modeli, na podstawie pomiarów, wyznaczono średni czas przetwarzania pojedynczej klatki i średnią liczbę klatek na sekundę (z ang. frames per second, fps), które przedstawiono w tabeli 2.

Zastosowany model YOLOv8x uruchomiony w przedstawionej konfiguracji sprzętowej, mimo swojej złożoności, zapewnił akceptowalną wydajność podczas testów skuteczności rozpoznawania.

Tabela 2. Średni czas przetwarzania pojedynczej klatki i średnia liczba klatek na sekundę (FPS) dla wytrenowanych modeli

zestaw	zaznaczenie			
	mniejsze		większe	
	czas przetw. 1 kl. [ms]	fps	czas przetw. 1 kl. [ms]	fps
1	125,78	7,95	125,37	7,98
2	124,73	8,02	124,55	8,03
3	125,59	7,96	125,07	8,00
4	125,48	7,97	125,58	7,96

Eksperyment

W ramach eksperymentu wykonano testy skuteczności wytrenowanych modeli na utworzonej bazie danych. Każdy test został przeprowadzony na tych samych parametrach predykcji, tj. progu pewności wynoszącym 0,4 oraz IoU (ang. intersection over union) wynoszącym również 0,4. Parametr IoU oznacza stopień pokrywania się obszaru predykowanego i faktycznego obszaru obiektu, czyli stosunek części wspólnej ramek tych obszarów do ich sumy [24]. Uzyskane wyniki przedstawiono w tabeli 3, gdzie klasą pozytywną było powalone drzewo. W przypadku prawdziwie pozytywnego (PP) wyniku rozpoznawania powalone drzewo było wykryte w miejscu, w którym faktycznie się znajdowało. W przypadku fałszywie pozytywnym (FP) model wykrył powalone drzewo w miejscu, w którym w rzeczywistości się ono nie znajdowało. W przypadku fałszywie negatywnym (FN) model nie wykrył drzewa, które znajdowało się na obrazie. W przypadku prawdziwie negatywnym (PN) model nie wykrył powalonego drzewa na obrazie, na którym nie znajdowało się żadne powalone drzewo.

Do opisu zastosowano typowe miary skuteczności rozpoznawania, tj. dokładność, precyzję, czułość i miarę F1 [24–26]. Dokładność wskazuje liczbę poprawnych predykcji względem liczby wszystkich predykcji, czyli określa jaka ich część została wykonana poprawnie. Precyzja opisuje liczbę poprawnych wykryć klasy pozytywnej względem wszystkich jej wykryć. Umożliwia ona ocenę jak dużo spośród wykryć wykonanych przez model rzeczywiście przedstawiało

Tabela 3. Wyniki testów skuteczności rozpoznawania powalonych drzew dla różnych zaznaczeń i zestawów augmentacji

zaznaczenie (trening / test)	zestaw	tabela pomyłek					miary skuteczności [%]			
		PP	PN	FN	FP1 (*)	FP2 (**)	dokładność	precyzja	czułość	miara F1
mniejsze / mniejsze	1	18	29	12	9	1	68	64	60	62
	2	17	28	13	7	2	67	65	57	61
	3	27	28	3	7	2	82	75	90	82
	4	24	30	6	3	0	86	89	80	84
większe / większe	1	27	26	3	4	4	83	77	90	83
	2	25	29	5	4	1	84	83	83	83
	3	25	28	5	4	2	83	81	83	82
	4	26	30	4	1	0	92	96	87	91
mniejsze / pośrednie	1	19	29	11	8	1	71	68	63	66
	2	17	28	13	7	2	67	65	57	61
	3	27	28	3	7	2	82	75	90	82
	4	24	30	6	3	0	86	89	80	84
większe / pośrednie	1	26	26	4	5	4	80	74	87	80
	2	24	29	6	5	1	82	80	80	80
	3	26	28	4	3	2	86	84	87	85
	4	23	30	7	4	0	83	85	77	81

* FP na klatkach z powalonymi drzewami, ** FP na klatkach referencyjnych

powalone drzewo, określając jak dobrze model interpretował rozpoznane obiekty. Czułość, wskazująca liczbę poprawnych wykryć klasy pozytywnej względem wszystkich etykiet danych klasy pozytywnej, pozwala oceniać zdolności modelu do wykrywania powalonych drzew znajdujących się na obrazach. Miara F1 jest harmoniczną średnią precyzji i czułości.

Najlepsze wyniki dokładności (92%) i miary F1 (91%) uzyskano dla większych zaznaczeń oraz równoczesnego wykorzystania obu typów augmentacji. Zwiększenie zasobu obrazów za pomocą augmentacji zwiększało prawidłowo wykrytą powierzchnię drzewa. Model wytrenowany na bazie z mniejszymi zaznaczeniami miał tendencję do pomijania jednostkowych przypadków drzew powalonych pod większym kątem względem płaszczyzny drogi.

Jako demonstrator, przygotowano aplikację do automatycznego rozpoznawania powalonych drzew z graficznym interfejsem użytkownika. Użytkownik może wybrać model, za pomocą którego zostanie dokonana detekcja i, korzystając z eksploratora plików, może wybrać obraz lub plik wideo, na którym będzie dokonana detekcja. Za pomocą suwaka można zmienić granicę pewności predykcji. Aplikacja wspiera również detekcję w czasie rzeczywistym z wykorzystaniem obrazu pochodzącego z kamery wbudowanej lub zewnętrznej.

Podsumowanie i wnioski

Wykazano, że automatyczne rozpoznawanie powalonych drzew z perspektywy wideorejestratorów samochodowych jest możliwe z dokładnością przekraczającą 90%, w warunkach ograniczonego zbioru danych i przy dużej różnorodności obiektów. Sprzyjają temu konsekwentny sposób zaznaczania obszarów obiektów oraz zwielokrotnianie danych uczących przy pomocy metod augmentacji.

Wraz ze wzrostem liczby dostępnych danych, modele sztucznych sieci neuronowych mogłyby być trenowane na coraz większych zbiorach. Zaproponowany system do rozpoznawania powalonych drzew na drodze mógłby być kolejnym elementem wspomagającym pracę kierowcy, oferowanym w seryjnie wytwarzanych pojazdach.

Badania sfinansowano z subwencji badawczej 0211/SBAD/0225.

Przyjęto: 05.10.2025, **zaakceptowano:** 04.11.2025, **opublikowano:** 24.11.2025

LITERATURA

[1] Neumann T., Analysis of Advanced Driver-Assistance Systems for Safe and Comfortable Driving of Motor Vehicles, Sensors, 24 (2024), no. 19, 6223, doi: 10.3390/s24196223.
[2] Park J., Lee J., Park Y., Lim Y., Deep Learning-Based Stopped Vehicle Detection Method Utilizing In-Vehicle Dashcams, Electronics, 13 (2024), no. 20, 4097, doi: 10.3390/electronics13204097.
[3] Balcerek J., Pawłowski P., Dolny K., Skotnicka J., Automatic recognition of emergency vehicles in images from video recorders, 2024 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA), Poznan, Poland, 2024, 85-90, doi: 10.23919/SPA61993.2024.10715603.
[4] Balcerek J., Pawłowski P., Trzciński B., System wizyjny do automatycznego rozpoznawania zwierząt na nagraniach z wideorejestratorów samochodowych, Przegląd Elektrotechniczny, 99 (2023), nr 10, 278–281, doi: 10.15199/48.2023.10.58.
[5] Balcerek J., Pawłowski P., Cierpiszewska J., Kus Ł., Zborowski P., Automatic recognition of dangerous objects in front of the vehicle's windshield, 2024 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA), Poznan, Poland, 2024, 91-96, doi: 10.23919/SPA61993.2024.10715613.
[6] Polska Akademia Nauk : Komitet ds. Kryzysu Klimatycznego, Komunikat 01/2024 Komitetu Problemowego ds. Kryzysu Klimatycznego przy Prezydium PAN na temat wpływu zmiany klimatu na lasy i lasów na klimat, Warszawa, 05.01.2024.
[7] Główny Urząd Statystyczny : Urząd Statystyczny w Białymstoku, Rocznik Statystyczny Leśnictwa, Warszawa, Białystok, 2024.
[8] Komenda Główna Policji : Biuro Ruchu Drogowego, Wypadki drogowe w Polsce w 2023 roku, Warszawa, 2024.
[9] Pretzsch H., Biber P., Schütze G., Kemmerer J., Uhl E., Wood density reduced while wood volume growth accelerated in Central European forests since 1870, Forest Ecology and Management, vol. 429 (2018), 589–616, doi: 10.1016/j.foreco.2018.07.045.
[10] Polewski P., Yao W., Heurich M., Krzystek P., Stilla U., Detection of fallen trees in ALS point clouds by learning the Normalized Cut similarity function from simulated samples, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, vol. II–3 (2014), 111–118, doi: 10.5194/isprsannals-II-3-111-2014.
[11] Heinaro E., Tanhuanpää T., Yrttimaa T., Holopainen M., Vastaranta M., Airborne laser scanning reveals large tree trunks on forest floor, Forest Ecology and Management, vol. 491 (2021), 119225, doi: 10.1016/j.foreco.2021.119225.
[12] Heinaro E., Tanhuanpää T., Vastaranta M., Yrttimaa T., Kukko A., Hakala T., Mattsson T., Holopainen M., Evaluating Factors Impacting Fallen Tree Detection from Airborne Laser Scanning Point Clouds, Remote Sensing, 15 (2023), no. 2, 382, doi: 10.3390/rs15020382.
[13] Kogut T., Wancel D., Stępień G., Smuga-Kogut M., Szostak M., Całka B., Risk of Tree Fall on High-Traffic Roads: A Case Study of the S6 in Poland, Applied Sciences, 14 (2024), no. 11, 4479, doi: 10.3390/app14114479.
[14] Moon H., Park E., Moon J., Lee J., Lee M., Kim D., Lee M., Matson E. T., Cost-Effective Solution for Fallen Tree Recognition Using YOLOX Object Detection, 2022 Sixth IEEE International Conference on Robotic Computing (IRC), Italy, 2022, 215–220, doi: 10.1109/IRC55401.2022.00043.
[15] Reder S., Mund J.-P., Albert N., Waßermann L., Miranda L., Detection of Windthrown Tree Stems on UAV-Orthomosaics Using U-Net Convolutional Networks, Remote Sensing, 14 (2022), no. 1, 75, doi: 10.3390/rs14010075.
[16] Mäyrä J., Tanhuanpää T., Kuzmin A., Heinaro E., Kumpula T., Vihervaara P., Using UAV images and deep learning to enhance the mapping of deadwood in boreal forests, Remote Sensing of Environment, vol. 329 (2025), 114906, doi: 10.1016/j.rse.2025.114906.
[17] Yoshii T., Matsumura N., Lin C., Integrating UAV-SfM and Airborne Lidar Point Cloud Data to Plantation Forest Feature Extraction, Remote Sensing, 14 (2022), no. 7, 1713, doi: 10.3390/rs14071713.
[18] Xu M., Yoon S., Fuentes A., Park D. S., A Comprehensive Survey of Image Augmentation Techniques for Deep Learning, Pattern Recognition, vol. 137 (2023), 109347, doi: 10.1016/j.patcog.2023.109347.
[19] Zoph B., Cubuk E. D., Ghiasi G., Lin T.-Y., Shlens J., Le Q. V., Learning Data Augmentation Strategies for Object Detection, In: Vedaldi A., Bischof H., Brox T., Frahm J.-M. (eds), Computer Vision – ECCV 2020, ECCV 2020, Lecture Notes in Computer Science, vol. 12372 (2020), Springer, Cham., doi: 10.1007/978-3-030-58583-9_34.
[20] Google, Google Colaboratory (Colab), https://colab.research.google.com (dostęp: 04.03.2025).
[21] NVIDIA Corporation, NVIDIA A100 Tensor Core GPU, 2025, https://www.nvidia.com/en-us/data-center/a100/ (dostęp: 04.03.2025).
[22] Jocher G., Chaurasia A., Qiu J., Ultralytics YOLOv8, 2023, https://github.com/ultralytics/ultralytics, GitHub, Inc., Ultralytics Inc., https://ultralytics.com.
[23] Ultralytics Inc., Ultralytics YOLO Docs, Explore Ultralytics YOLOv8, 2025, https://docs.ultralytics.com/models/yolov8/ (dostęp: 04.03.2025).
[24] Padilla R., Netto S. L., da Silva E. A. B., A Survey on Performance Metrics for Object-Detection Algorithms, 2020 International Conference on Systems, Signals and Image Processing (IWSSIP), Niteroi, Brazil, 2020, 237–242, doi: 10.1109/IWSSIP48289.2020.9145130.
[25] Noola D. A., Basavaraju D. R., Corn leaf image classification based on machine learning techniques for accurate leaf disease detection, International Journal of Electrical and Computer Engineering (IJECE), vol. 12 (2022), no. 3, 2509-2516, doi: 10.11591/ijece.v12i3.pp2509-2516.
[26] Sasaki Y., The truth of the F-measure, Teach Tutor Mater, 2007, 1–5.