

# Automatyczne rozpoznawanie elementów polskich pojazdów historycznych

**Streszczenie.** W niniejszym artykule zaprezentowano system do automatycznego rozpoznawania elementów polskich pojazdów historycznych. System dokonuje analizy obrazów za pomocą sztucznych sieci neuronowych. Do przeprowadzenia testów skuteczności klasyfikacji wybranych zbiorów klas obiektów przygotowano bazę obrazów, z uwzględnieniem pochodzenia, modułu, modelu, nadwozia, silnika i wnętrza. Dla sieci wytrenowanych na pojedynczych modułach pojazdów w dwóch przypadkach osiągnięto stuprocentową dokładność klasyfikacji.

**Abstract.** This article presents a system for automatic recognition of elements of Polish historical vehicles. The system uses artificial neural networks for image analysis. A database of images was prepared to carry out the classification tests of selected sets of object classes, taking into account the origin, module, model, engine, body, and interior. For networks trained on single vehicle module, even 100% classification accuracy was achieved in two cases. (**Automatic recognition of elements of Polish historical vehicles**).

**Słowa kluczowe:** polskie pojazdy historyczne, system wizyjny, analiza obrazów, sztuczne sieci neuronowe.

**Keywords:** Polish historical vehicles, vision system, image analysis, artificial neural networks.

## 1. Wprowadzenie

Systemy do automatycznego rozpoznawania elementów pojazdów, oparte na sztucznych sieciach neuronowych, mogą być wykorzystywane do wykrywania poszczególnych części w celu rozpoznawania uszkodzeń i szacowania kosztów napraw [1–3]. Mogą też służyć jako pomoc dla użytkownika w obsłudze pojazdu [4, 5] lub do określania marki samochodu poprzez identyfikację logo [6, 7].

Spotykane systemy dotyczą głównie współczesnych pojazdów. Pojazdy zabytkowe stanowią z kolei część dziedzictwa narodowego [8], a ich dokumentacja i analiza odgrywają ważną rolę w dziedzinie motoryzacji, badaniu jej historii i edukacji w tym zakresie. Uwarunkowania te wskazują na potrzebę przygotowania systemu do rozpoznawania elementów polskich pojazdów historycznych.

Do rozpoznawania elementów pojazdów przez automatyczne oprogramowanie, wytypowano dwa główne modele pojazdów: Fiata 125p z 1973 roku oraz Tarpana 233 z lat 1977-1982, które przedstawiono na rysunku 1. Selekcja ta została dokonana z uwzględnieniem kilku czynników.



Rys. 1. Polskie pojazdy historyczne: a) Fiat 125p, b) Tarpan 233

Jednym z nich była dostępność i możliwość wykonania zdjęć na terenie Muzeum Rolnictwa i Przemysłu Rolno-Spożywczego w Szreniawie [9], za zgodą Dyrektora Muzeum. Pozwoliło to na sporządzenie bazy obrazów złożonej głównie z autorskich fotografii. Ze strony Muzeum udostępnione były również informacje o eksponatach znajdujących się na ekspozycji.

Ponadto, oba pojazdy dzieliły wiele wspólnych części. Dzięki temu możliwe było dodanie stopnia klasyfikacji, określającego przynależność części do jednego modelu lub wskazanie, że były one montowane w obu samochodach.

Dodatkowo, za wyborem Tarpana 233 stał aspekt regionalny, ponieważ był on samochodem produkowanym w Wielkopolsce. Uznano, że warto podkreślić unikalne cechy pojazdu oraz wkład tego regionu Polski w rozwój polskiej motoryzacji.

Wartym przytoczenia jest fakt, że w roku 2023 (w którym został przygotowywany prezentowany system) miały dwie 50-te rocznice: rozpoczęcia produkcji pojazdu Tarpan oraz bicia rekordów świata w prędkości podczas jazdy na długim dystansie (25 tys. km, 50 tys. km oraz 25 tys. mil) przez serjiny samochód osobowy Fiat 125p [10].

W niniejszej pracy zaproponowano i przetestowano możliwości automatycznego rozpoznawania wybranych elementów polskich pojazdów historycznych na podstawie analizy obrazów, skupiając się na etapie klasyfikacji. Uwzględniono podział na wybrane klasy odnoszące się do elementów polskich pojazdów historycznych, a do klasyfikacji wykorzystano sztuczne sieci neuronowe. Testy przeprowadzono na specjalnie przygotowanej bazie obrazów.

## 2. Baza obrazów elementów polskich pojazdów historycznych

Wykonanie i przetestowanie systemu do rozpoznawania elementów pojazdów wymagało przygotowania odpowiedniej bazy obrazów.

Większość ze zdjęć wykonano własnoręcznie. Głównym źródłem były obrazy zarejestrowane na terenie Muzeum. Zdjęcia elementów zostały wykonane z zewnątrz, wewnątrz oraz pod maską samochodów. Ponadto silnik oraz deskę rozdzielczą Tarpana sfotografowano na wystawie, gdzie były prezentowane jako osobne eksponaty.

Zdjęcia rejestrowano urządzeniem Samsung Galaxy A52 SM-A525F/DS z wbudowanym aparatem o maksymalnej rozdzielczości 64 Mpix, a zapisywane na telefonie miały rozdzielczość 4624x3468 pikseli. Bazę obrazów uzupełniono o inne autorskie fotografie oraz wyszukane w sieci obrazy, udostępnione na licencji Creative Commons [11].

Przygotowana baza zawierała zdjęcia elementów pojazdów Tarpan 233 oraz Fiat 125p, a także fotografie przedstawiające elementy innych pojazdów oraz zdjęcia nieprzeznaczające pojazdów. Po wyodrębnieniu obiektów ze zdjęć, zawierała w sumie 1948 obrazów.

Bazę podzielono na sześć zbiorów klas, dotyczących ogólnego pochodzenia, modułu i modelu pojazdu, elementów nadwozia, silnika oraz wnętrza. Liczbę obrazów w klasach należących do poszczególnych zbiorów klas przedstawiono w tabeli 1.

Pierwszy zbiór klas, dotyczący ogólnej klasyfikacji pochodzenia obiektów, obejmował określanie, czy element na zdjęciu należał do listy wybranych części Fiata 125p i Tarpana 233, czy też miał inne pochodzenie.

Tabela 1. Liczba obrazów w poszczególnych zbiorach klas

klasy	zbiory klas					
	1	2	3	4	5	6
	ogólne pochodzenie	moduł	model	nadwozie	silnik	wnętrze
1	wybrane elementy Fiata 125p i Tarpana 233	nadwozie	Fiat 125p	kierunkowskaz boczny	blok silnika	kierownica
	1349	659	151	52	76	42
2	inne elementy Fiata 125p i Tarpana 233	silnik	Tarpan 233	klamka zewnętrzna	regulator napięcia	klamka wewnętrzna
	152	337	301	83	77	43
3	elementy innych polskich pojazdów historycznych	wnętrze	wspólne	korek wlewu paliwa	talerzowy filtr powietrza	lampka oświetlenia wnętrza
	177	353	897	49	117	31
4	elementy innych pojazdów	–	–	lampa zespolona przednia	zbiornik płynu do chłodnicy	mechanizm blokady drzwi
	170	–	–	106	67	35
5	inne (nie-pojazdy)	–	–	lampka oświetlenia tablicy rejestracyjnej	–	przełączniki zespolone
	100	–	–	104	–	140
6	–	–	–	logo	–	zegary
	–	–	–	73	–	62
7	–	–	–	reflektor	–	–
	–	–	–	138	–	–
8	–	–	–	zderzak przedni	–	–
	–	–	–	54	–	–
suma	1948	1349	1349	659	337	353

Jeśli obiekt nie był wybranym komponentem tych pojazdów, uwzględniono cztery inne przypadki, tj. przynależność do innych elementów Fiata 125p i Tarpana 233, elementów innych polskich pojazdów historycznych, elementów innych pojazdów oraz do obiektów innych niż pojazdy. Obrazy z tych czterech klas nie były przeznaczone do wykorzystania w kolejnych zbiorach klas.

Do klasy zawierającej inne elementy wybranych polskich pojazdów historycznych wybrano fotografie elementów z samochodów Fiat 125p i Tarpan 233, ale części te były spoza listy wybranych elementów. Należały do nich wycieraczki, lusterka i lampy tylne obu modeli. Zdjęcia z klasy elementów innych polskich pojazdów historycznych zawierały elementy należące do pojazdów Syrena, Warszawa oraz Fiat 126p. W klasie z elementami innych pojazdów, oprócz współcześnie stosowanych zestawów zegarów i klamek, zostały umieszczone zdjęcia innych elementów, takich jak: reflektory przednie, kierownice, lampy tylne, lusterka, czy też silniki. W ostatniej kategorii, tj. inne (nie-pojazdy), znalazły się zdjęcia ukazujące sceny i obiekty różne od samochodów. Wśród nich można było znaleźć przede wszystkim fotografie roślin, zwierząt oraz budynków.


Drugi zbiór klas obejmował klasyfikację ze względu na moduł pojazdu. Elementy pojazdów zostały przyporządkowane do trzech kategorii: nadwozia, silnika oraz wnętrza. Suma obrazów w tych trzech kategoriach odpowiadała sumie zdjęć z klasy zawierającej wybrane elementy Fiata 125p i Tarpana 233, z pierwszego zbioru klas. Największy odsetek stanowiły obrazy nadwozia, o największej liczbie rodzajów elementów. Ze względu na dostępność do fotografowania, zdjęcia pochodziły z większej liczby pojazdów niż w przypadku wnętrza i części silnikowych.

Trzeci zbiór klas dotyczył przyporządkowania elementów pojazdu do modelu pojazdu. Wybrane elementy w danej postaci mogły występować tylko we Fiacie 125p lub tylko w Tarpanie 233 (elementy rozłączne), lub występować w takiej samej postaci w obu pojazdach (elementy wspólne), co przedstawiono w tabeli 2.


Tabela 2. Elementy wspólne i rozłączne pojazdów Fiat 125p (1973) oraz Tarpan 233 (1977-1982)

elementy	
wspólne	rozłączne
<ul style="list-style-type: none"> <li>• lampa kierunkowskazu bocznego</li> <li>• korek wlewu paliwa</li> <li>• lampa zespolona przednia</li> <li>• lampa oświetlenia tablicy rejestracyjnej</li> <li>• blok silnika</li> <li>• regulator napięcia</li> <li>• talerzowy filtr powietrza</li> <li>• zbiornik płynu do chłodnicy</li> <li>• klamka wewnętrzna</li> <li>• lampka oświetlenia wnętrza</li> <li>• mechanizm blokady drzwi</li> <li>• przełączniki zespolone</li> </ul>	<ul style="list-style-type: none"> <li>• klamki zewnętrzne do drzwi</li> <li>• logo</li> <li>• reflektor przedni</li> <li>• zderzak przedni</li> <li>• koło sterowe</li> <li>• kierownice</li> <li>• zegary</li> </ul>


Dokonano też podziału na trzy zbiory klas elementów pojazdów, tzn. zawierające elementy nadwozia (czwarty zbiór klas, rysunek 2), silnika (piąty zbiór klas, rysunek 3) oraz wnętrza (szósty zbiór klas, rysunek 4) samochodów Fiat 125p i Tarpan 233.



Rys. 2. Przykładowe obrazy z czwartego zbioru klas: a) kierunkowskaz boczny, b) klamka zewnętrzna, c) korek wlewu paliwa, d) lampa zespolona przednia, e) lampka oświetlenia tablicy rejestracyjnej, f) logo, g) reflektor przedni, h) zderzak przedni



Rys. 3. Przykładowe obrazy z piątego zbioru klas: a) blok silnika, b) regulator napięcia, c) talerzowy filtr powietrza, d) zbiornik płynu do chłodnicy



Rys. 4. Przykładowe obrazy z szóstego zbioru klas: a) kierownica, b) klamka wewnętrzna, c) lampka oświetlenia wnętrza, d) mechanizm blokady drzwi, e) przełączniki zespolone, f) zegary

Łącznie przygotowano 18 klas, a liczba zdjęć poszczególnych części składała się na wszystkie obrazy wybranych elementów Fiata 125p i Tarpana 233.

W ramach każdej klasy obrazy podzielono na dane do treningu spłotowych sieci neuronowych (około 60% obrazów), walidacji (około 20% obrazów) i testów (około 20% obrazów). Liczba obrazów w zbiorze walidacyjnym i testowym była taka sama dla wszystkich sześciu klas.

### 3. Architektura spłotowych sieci neuronowych

Automatyczne rozpoznawanie elementów polskich pojazdów historycznych zostało zrealizowane na podstawie klasyfikacji obiektów na obrazach z przygotowanej bazy. Do tego zadania wykorzystano spłotowe sztuczne sieci neuronowe i dodatkowe narzędzia programistyczne.


System przygotowano w środowisku Anaconda [12]. Kod źródłowy został napisany w języku Python [13]. W ramach jego dystrybucji dostępny był szeroki wybór bibliotek i narzędzi do uczenia maszynowego i przetwarzania obrazów. Kod skryptu odpowiedzialnego za przygotowanie danych do treningu, walidacji i testu został napisany i skompilowany w środowisku PyCharm, które dostarczyło funkcji niezbędnych do programowania i zarządzania przygotowywanym oprogramowaniem [14]. Do kompilacji kodu odpowiedzialnego za trening i testy modeli sieci neuronowych wykorzystano narzędzie Jupyter Notebook. Umożliwiało ono tworzenie dokumentów zawierających kod i przeprowadzanie testów powstałego oprogramowania [15].

Bibliotekę TensorFlow [16], przeznaczoną do uczenia maszynowego, wykorzystano do etapów, takich jak: wczytanie modeli oraz ich kompilacja, przeprowadzenie procesu treningu, walidacji i testowania. Biblioteka Keras [17] została wykorzystana do budowy modelu, dodawania warstw, kompilacji modelu oraz do przygotowania danych do treningów, walidacji i testów. Bibliotekę „scikit-learn” [18] wykorzystano do obliczenia wartości metryk, tj. precyzji, czułości i punktacji F1 (ang. F1-score), po skończonych treningach i testach sieci neuronowych. Bibliotekę „numpy” [19] wykorzystano do obliczeń i operacji na tablicach danych.

Obrazy z przygotowanej bazy zostały wstępnie przetworzone: dokonano augmentacji obrazów oraz ich skalowania. Augmentacja, polegająca na dodaniu do materiału treningowego nieznacznie zmodyfikowanych replik już istniejących danych miała na celu zwiększenie różnorodności obrazów w zbiorach treningowych. Etap ten korzystnie wpływa na rezultaty algorytmów uczenia maszynowego i typowo zwiększa odporność sieci na zmiany, np. orientacji obiektów, czy też ich położenia na obrazie [20].

Podczas augmentacji zastosowano trzy modyfikacje obrazów, wykonywane losowo na bazie treningowej. Były to: lustrzane odbicie, powiększenie lub pomniejszenie oraz zmiana kąta nachylenia obrazu. Na rysunku 5 przedstawiono przykład oryginalnego zdjęcia oraz obrazy po zastosowaniu wymienionych przekształceń.

Skalowanie polegało na zmianie rozdzielczości wszystkich obrazów do jednego rozmiaru wynoszącego 224×224 piksele. W przypadku potrzeby interpolacji punktów, wykorzystano metodę najbliższego sąsiada. W przypadku obrazów o różnych wartościach wysokości i szerokości, dozwolono na zniekształcanie ich proporcji [21].



Rys. 5. Przykłady augmentacji obrazów: a) obraz oryginalny, b) obraz pochylony, c) obraz przybliżony, d) obraz po zastosowaniu lustrzanego odbicia

Przed treningiem zdefiniowane zostały parametry uczenia. Dla obu wybranych modeli sieci neuronowych, tj. ResNet-50 i VGG-19, były one jednakowe. Liczba przykładów treningowych przetwarzanych jednocześnie przez model podczas jednego kroku (parametr „batch size”) została ustalona na 8. Ustawiono maksymalną liczbę epok uczenia sieci na 100, choć trening mógł zostać zakończony przed osiągnięciem tego limitu, w przypadku spełnienia warunku zatrzymania. Warunek ten dotyczył braku spadku wartości funkcji straty na zbiorze walidacyjnym przez co najmniej 5 kolejnych epok. Dzięki temu zniwelowano ryzyko przetrenowania modeli sieci neuronowych. W procesie uczenia użyto optymalizatora Adam, o domyślnej wartości współczynnika uczenia wynoszącej 0,001. Funkcją straty, która była minimalizowana podczas treningu modeli, była entropia krzyżowa.

W celu przyspieszenia uczenia sieci neuronowych wykorzystano technikę GPGPU (ang. general-purpose processing on graphics processing unit) stosując kartę graficzną NVIDIA RTX 3060 z 6 GB pamięci. Przeprowadzono 12 treningów, tj. dla każdego z dwóch modeli i dla z sześciu zbiorów klas. Wytrenowane modele umożliwiły przeprowadzenie testów skuteczności klasyfikacji.

### 4. Eksperyment

W ramach eksperymentu przeprowadzono testy skuteczności przygotowanego oprogramowania na utworzonej bazie danych. Uzyskane wyniki przedstawiono w tabeli 3.

Tabela 3. Wyniki testów klasyfikacji dla sześciu zbiorów klas dla wybranych modeli sieci (ResNet-50 / VGG-19)

klasy	zbiory klas						
	1	2	3	4	5	6	
1	precyzja [%]	90/93	96/98	88/100	100/100	100/100	100/100
	czułość [%]	99/99	98/98	90/94	100/100	100/100	100/100
	miara F1 [%]	94/96	97/98	89/97	100/100	100/100	100/100
2	precyzja [%]	100/90	97/100	100/100	100/100	92/100	90/100
	czułość [%]	53/90	98/98	87/98	100/94	80/100	100/100
	miara F1 [%]	70/90	98/99	93/99	100/97	86/100	95/100
3	precyzja [%]	100/92	97/97	96/98	100/100	100/100	100/100
	czułość [%]	69/69	91/99	100/100	100/100	100/100	100/100
	miara F1 [%]	81/79	94/98	98/99	100/100	100/100	100/100
4	precyzja [%]	70/81	–	–	100/100	80/100	100/100
	czułość [%]	94/65	–	–	95/100	92/100	86/100
	miara F1 [%]	80/72	–	–	98/100	86/100	92/100
5	precyzja [%]	100/95	–	–	95/95	–	100/100
	czułość [%]	35/90	–	–	100/100	–	100/100
	miara F1 [%]	52/92	–	–	98/98	–	100/100
6	precyzja [%]	–	–	–	100/100	–	100/100
	czułość [%]	–	–	–	100/100	–	100/100
	miara F1 [%]	–	–	–	100/100	–	100/100
7	precyzja [%]	–	–	–	100/100	–	–
	czułość [%]	–	–	–	100/100	–	–
	miara F1 [%]	–	–	–	100/100	–	–
8	precyzja [%]	–	–	–	100/100	–	–
	czułość [%]	–	–	–	100/100	–	–
	miara F1 [%]	–	–	–	100/100	–	–
dokładność [%]	89/92	97/99	96/99	99/99	94/100	99/100	
śr. czas przetw. 1 klatki [ms]	10,2 / 10,5	10,5 / 10,6	10,3 / 10,2	9,4 / 10,3	14,5 / 15,0	12,9 / 12,7	
śr. liczba klatek na sekundę	98,5 / 95,6	95,1 / 94,1	97,4 / 97,8	106,4 / 97,1	68,8 / 66,7	77,8 / 78,7	

Oba modele osiągnęły wyniki dokładności przynajmniej na poziomie około 89%. Model VGG-19, w większości przypadków, uzyskiwał lepsze wartości metryk przy nieznacznie dłuższym czasie przetwarzania niż model ResNet-50.

Najlepsze wyniki oba modele prezentowały w klasyfikacji ze względu na ogólne pochodzenie obiektów (zbiór 1). Przynajmniej mógł być fakt występowania pewnych podobieństw elementów pojazdów należących do różnych klas



oraz istniała też duża różnorodność elementów. Na poprawę tego wyniku mogłoby wpłynąć powiększenie bazy obrazów treningowych.

Najwyższe wyniki skuteczności klasyfikacji (w dwóch przypadkach nawet o stu procentowej dokładności) osiągnięto dla sieci wytrenowanych na pojedynczych modułach pojazdów. Oznacza to, że najlepszą skuteczność klasyfikacji osiąga sieć wyspecjalizowana w celu klasyfikacji elementów pojazdu wchodzących w skład danego, pojedynczego modułu nadwozia, silnika lub wnętrza.

Dodatkowo, przygotowano aplikację do automatycznego rozpoznawania elementów polskich pojazdów historycznych, przeznaczoną do uruchamiania w przeglądarce internetowej, tj. działającą zarówno na urządzeniach mobilnych, jak i stacjonarnych. Za pomocą graficznego interfejsu użytkownika ma możliwość automatycznej kaskadowej analizy przesłanych zdjęć celem rozpoznawania części pojazdów przy wykorzystaniu opisanych wyżej, wytrenowanych modeli sztucznych sieci neuronowych.

## 6. Podsumowanie i wnioski

Na podstawie przeprowadzonych testów skuteczności przygotowanego oprogramowania można stwierdzić, że przy użyciu metod sztucznej inteligencji, zastosowanych do analizy obrazów, możliwe jest uzyskanie satysfakcjonujących wyników automatycznego rozpoznawania wybranych elementów polskich pojazdów historycznych.

W przyszłości liczba elementów pojazdów, a tym samym liczba klas, mogłaby zostać zwiększona. Etap klasyfikacji mógłby zostać poprzedzony etapem automatycznej detekcji obiektów. Ponadto, można by zwiększyć liczbę obrazów przedstawiających obiekty i tym samym zwiększyć zbiór danych do treningu, co mogłoby poprawić skuteczność klasyfikacji.

Automatyczne rozpoznawanie elementów polskich pojazdów historycznych posiada potencjał do pełnienia różnych funkcji. Może mieć walor edukacyjny w szkołach, np. kształcących w branży motoryzacyjnej, muzeach i innych miejscach, gdzie umożliwi poznanie tych pojazdów w interaktywny sposób. Dodatkowo, może stanowić wsparcie w przypadku konserwacji zabytków i ułatwiać wyszukiwanie, rozpoznawanie i weryfikację części na portalach aukcyjnych lub w magazynach.

*Autorzy artykułu serdecznie dziękują: za zgodę na pozyskanie materiałów fotograficznych do przeprowadzenie eksperymentu Dyrektorowi Muzeum Narodowego Rolnictwa i Przemysłu Rolno-Spożywczego w Szreniawie, dr. Janowi Maćkowiakowi, za uprzejmość i wskazówki Kustoszowi Muzeum, p. Gerardowi Radeckiemu oraz innym pracownikom Muzeum zaangażowanym w ten projekt.*

*Zdjęcia przedstawiające wizerunki pojazdów (obrazy na rysunkach 1-5) zostały wykonane za zgodą Dyrektora Muzeum Narodowego Rolnictwa i Przemysłu Rolno-Spożywczego w Szreniawie, obiekty stanowią ekspozycję Muzeum.*

*Badania sfinansowano z subwencji badawczej 0211/SBAD/0224.*

**Autorzy:** dr inż. [Julian Balcerek](mailto:julian.balcerek@put.poznan.pl), Politechnika Poznańska, Instytut Automatyki i Robotyki, ul. Piotrowo 3a, 60-965 Poznań, E-mail: [julian.balcerek@put.poznan.pl](mailto:julian.balcerek@put.poznan.pl); prof. dr hab. inż. Adam Dąbrowski, Politechnika Poznańska, Instytut Automatyki i Robotyki, ul. Piotrowo 3a, 60-965 Poznań, E-mail: [adam.dabrowski@put.poznan.pl](mailto:adam.dabrowski@put.poznan.pl); dr inż. Paweł Pawłowski, Politechnika Poznańska, Instytut Automatyki i Robotyki, ul. Piotrowo 3a, 60-965 Poznań, E-mail: [pawel.pawlowski@put.poznan.pl](mailto:pawel.pawlowski@put.poznan.pl); mgr inż. Piotr Tokarski, Politechnika Poznańska, Instytut Automatyki i Robotyki, ul. Piotrowo 3a, 60-965 Poznań, E-mail: [piotr.m.tokarski@student.put.poznan.pl](mailto:piotr.m.tokarski@student.put.poznan.pl).

## LITERATURA

- [1] Kumar A, Vehicle part detection using AI for vehicle damage and repair estimation, Inspektlabs, 12.07.2022, <https://inspektlabs.com/blog/vehicle-part-detection-using-ai-for-vehicle-damage-and-repair-estimation/> (dostęp: 03.03.2024).
- [2] Pasupa K., Kittiworapanya P., Hongngern N., Woraratpanya K., Evaluation of deep learning algorithms for semantic segmentation of car parts, Complex & Intelligent Systems, 8, pp. 3613–3625, 2022, doi: 10.1007/s40747-021-00397-8.
- [3] Parhizkar M., Amirfakhrian M., Recognizing the Damaged Surface Parts of Cars in the Real Scene Using a Deep Learning Framework, Mathematical Problems in Engineering, vol. 2022, Article ID 5004129, 7 pages, 2022, doi: 10.1155/2022/5004129.
- [4] Balcerek J., Hinc M., Jalowski Ł., Michalak J., Rabiza M., Konieczka A., Vision-based mobile application for supporting the user in the vehicle operation, 2019 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA), Poznan, Poland, pp. 250-255, 2019, doi: 10.23919/SPA.2019.8936754.
- [5] Jugroop G., Seegolum P., Chiniah A., Humaïra B. B., Computer Vision based Automated Spare Part Finder App, 2022 International Conference on Applied Artificial Intelligence and Computing (ICAAC), Salem, India, pp. 1101-1106, 2022, doi: 10.1109/ICAAC53929.2022.9792778.
- [6] Huang Y., Wu R., Sun Y., Wang W., Ding X., Vehicle Logo Recognition System Based on Convolutional Neural Networks With a Pretraining Strategy, IEEE Transactions on Intelligent Transportation Systems, vol. 16, no. 4, pp. 1951-1960, Aug. 2015, doi: 10.1109/TITS.2014.2387069.
- [7] Sadeq J. M., Qadir B. A., Abbas H. H., Cars logo recognition by using of backpropagation neural networks, Measurement: Sensors, vol. 26, April 2023, doi: 10.1016/j.measen.2023.100702.
- [8] Mazurek A., Ochrona zabytkowych pojazdów w polskim systemie prawnym, Ochrona zabytków, str. 217-238, nr 1, 2021.
- [9] Muzeum Narodowe Rolnictwa i Przemysłu Rolno-Spożywczego w Szreniawie, <https://muzeum-szreniawa.pl> (dostęp: 03.03.2024).
- [10] Muzeum Narodowe Rolnictwa i Przemysłu Rolno-Spożywczego w Szreniawie, Spotkanie poświęcone Jubileuszom 50-lecia uruchomienia produkcji Tarpanów oraz rekordów Polskiego Fiata 125p, <https://muzeum-szreniawa.pl/50-lat-rekordow-polskiego-fiata-i-produkcji-tarpana-i-niecodzienne-odwiedziny-muzeum/> (dostęp: 03.03.2024).
- [11] Creative Commons, <https://creativecommons.org> (dostęp: 09.07.2023).
- [12] Anaconda Inc., Anaconda, <https://www.anaconda.com> (dostęp: 09.07.2023).
- [13] Python Software Foundation, Python, <https://www.python.org> (dostęp: 09.07.2023).
- [14] JetBrains s.r.o., PyCharm, The Python IDE for Professional Developers, <https://www.jetbrains.com/pycharm/> (dostęp: 09.07.2023).
- [15] Project Jupyter, Jupyter, <https://jupyter.org> (dostęp: 09.07.2023).
- [16] Abadi M. et al., TensorFlow: Large-scale machine learning on heterogeneous systems, 2015, software available from tensorflow.org.
- [17] Keras, Simple. Flexible. Powerful., <https://keras.io> (dostęp: 09.07.2023).
- [18] Scikit-learn, Machine Learning in Python, <https://scikit-learn.org/stable/> (dostęp: 09.07.2023).
- [19] NumPy team, Numpy, The fundamental package for scientific computing with Python, <https://numpy.org> (dostęp: 03.03.2024).
- [20] Raj B, Data Augmentation | How to use Deep Learning when you have Limited Data — Part 2, Medium, 11 April 2018, <https://medium.com/nanonets/how-to-use-deep-learning-when-you-have-limited-datapart-2-data-augmentation-c26971dc8ced> (dostęp: 09.07.2023).
- [21] Tensorflow, tf.keras.preprocessing.image.ImageDataGenerator, [https://www.tensorflow.org/api\\_docs/python/tf/keras/preprocessing/image/ImageDataGenerator](https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator) (dostęp: 09.07.2023).