

Politechnika Poznańska
Wydział Inżynierii Mechanicznej



ROZPRAWA DOKTORSKA

**Badanie i modelowanie procesów
technologicznych opon na maszynach
VMI MAXX w celu uzyskania określonych
wyników jednorodności**

Wojciech Majewski

Promotor:

dr hab. inż. Ewa DOSTATNI, prof. PP

Promotor pomocniczy:

dr inż. Jacek DIAKUN

Poznań 2025

Spis treści

Streszczenie	4
Summary	5
1. Wprowadzenie.....	6
2. Budowa opon radialnych.....	8
3. Proces produkcji opon radialnych	16
3.1 Przygotowanie materiałów	16
3.2 Konfekcja opon na maszynie VMI MAXX	19
3.3 Wulkanizacja opon	28
3.4 Inspekcja końcowa	31
4. Kontrola jakości opon na tle wymagań klienta	33
4.1 Podział defektów opon oraz sposoby ich eliminacji	33
4.2 Specyfikacja wymagań klienta	38
4.3 Jednorodność opon	41
4.3.1 Zmienność siły promieniowej i jej wyższe harmoniczne.....	44
4.3.2 Zmienność siły bocznej	48
4.3.3 Balans statyczny i dynamiczny	53
4.3.4 Bicie promieniowe i bicie boczne	55
4.3.5 Stożkowatość i ply steer	56
4.3.6 Jednorodność przy wysokich prędkościach	67
4.4 Testy stacyjne opon	68
4.4.1 Analiza przekroju opony	69
4.4.2 Odcisk rzeźby bieżnika	75
4.4.3 Testy siły i ciśnienia osadzenia stopki	80
4.4.4 Testy bieżne opon (wysokich i niskich prędkości)	83
4.4.5 Wyznaczenie oporów toczenia opon	85
4.4.6 Opór elektryczny opon	87
4.4.7 Własności fizyczne mieszanki bieżnika	88
4.5 Testy homologacyjne	89
5. Współczesne kierunki badań opon samochodowych	91
6. Modele uczenia maszynowego.....	100
6.1 Rodzaje uczenia maszynowego.....	100
6.1.1 Uczenie nadzorowane	102

6.1.2	Uczenie nienadzorowane.....	113
6.1.3	Uczenie przez wzmacnianie	114
6.2	Cykl życia modelu uczenia maszynowego.....	115
6.3	Ocena działania modelu dla problemu regresji	124
7.	Część badawcza.....	127
7.1	Przedmiot badań	129
7.1.1	Pomiary komponentów składowych opony na maszynie VMI MAXX	129
7.1.2	Pomiary wielkości opisujących jednorodność opon na maszynach TUO i Rim Flow oraz dotychczasowy przepływ danych.....	132
7.2	Gromadzenie, przygotowanie i analiza danych.....	134
7.2.1	Rejestracja i wstępne przetwarzanie danych	134
7.2.2	Eksploracyjna analiza danych	137
7.3	Trenowanie, ewaluacja i wybór modelu	154
7.3.1	Kryteria doboru mierników do oceny działania badanych modeli	154
7.3.2	Analiza zastosowania regresji liniowej wielu zmiennych.....	156
7.3.3	Analiza zastosowania modelu MLP	157
7.3.4	Analiza zastosowania modeli opartych na drzewach decyzyjnych.....	162
7.3.5	Analiza wyników i wybór modelu	168
7.4	Walidacja modelu.....	174
8.	Część wdrożeniowa.....	178
8.1	Implementacja modelu do systemu informatycznego przedsiębiorstwa oraz maszyn VMI MAXX.....	178
8.2	Monitorowanie i utrzymanie modelu oraz potencjalne efekty wdrożenia	181
9.	Wnioski	184
	Literatura	188

Streszczenie

W pracy skoncentrowano się na opracowaniu modelu przewidującego w czasie rzeczywistym wyniki stożkowatości opon na określonym poziomie, którego wdrożenie obniży liczbę defektów opon w firmie Bridgestone Poznań. Omówiono budowę, stosowane konstrukcje oraz komponenty składowe opon radialnych dedykowanych do samochodów osobowych. Scharakteryzowano przebieg procesu produkcji opon, wyszczególniając jego główne etapy, czyli: przygotowanie materiałów, konfekcję, wulkanizację i inspekcję końcową. Szczególną uwagę zwrócono na etap konfekcji, gdzie dodatkowo przybliżono budowę maszyny VMI MAXX. Dokonano podziału defektów opon na wizualne i związane z przekroczeniem limitów własności opisujących jednorodność opon, a także podano przykłady kierunków ich eliminacji. Przybliżono wielkości opisujące jednorodność opon z wyróżnieniem zjawisk promieniowych (tj. zmienność siły promieniowej, balans statyczny i dynamiczny, bicie promieniowe) i zjawisk bocznych (tj. zmienność siły bocznej, bicie boczne, ply steer) zwracając szczególną uwagę na stożkowatość. Wspomniano o pomiarze jednorodności opon przy wysokich prędkościach. Omówiono przebieg testów opon (tj. analiza przekroju, odcisk rzeźby bieżnika, testy bieżne wysokich i niskich prędkości, wyznaczanie oporów toczenia, pomiar siły i ciśnienia osadzenia stopki) pod kątem wymagań klienta i przepisów homologacyjnych. Sporządzono przegląd współczesnych kierunków rozwoju przemysłu oponiarskiego, na podstawie którego zauważono coraz częstsze wykorzystywanie metod uczenia maszynowego do poprawy procesu wytwarzania opon. Przedstawiono modele uczenia maszynowego najczęściej wykorzystywane w przemyśle. W toku badań porównano model regresji liniowej wielu zmiennych, modele sztucznych sieci neuronowych (perceptron wielowarstwowy) i modele oparte na drzewach decyzyjnych (XGBoost, FastTreeRegression i LightGbmRegression). Algorytmy trenowano na rzeczywistych danych z historycznego rejestru masowej produkcji opon. Możliwie najlepszą metodę do rozwiązania problemu wybrano na podstawie mierników RMSE i R^2 oraz realiów panujących w firmie. Wybrany model walidowano na szerszej grupie rozmiarów opon, które reprezentowały spektrum możliwości produkcyjnych maszyn VMI MAXX. Zaprezentowano obecny postęp wdrożenia rezultatów badań w systemie informatycznym przedsiębiorstwa oraz na maszynie VMI MAXX jako narzędzia do wspomagania masowej produkcji opon. Wskazano kierunek dalszych działań oraz opisano możliwe efekty kontynuacji prac wdrożeniowych.

Summary

The dissertation focused on developing a real-time predictive model for tire conicity at a specified level, aimed to reduce the number of tire defects in Bridgestone Poznań factory. The work discusses the structure, constructions and components of radial tires for passenger cars. The tire manufacturing process is outlined, with emphasis on its main stages: material preparation, tire building, vulcanization, and final inspection. Particular attention is given to the tire building stage, including a detailed description of the VMI MAXX machine. Tire defects are classified into visual issues and those exceeding tire uniformity limits, along with examples of elimination strategies. The study introduces parameters describing tire uniformity, distinguishing between radial phenomena (radial force variation, static and dynamic balance, radial runout) and lateral phenomena (lateral force variation, lateral runout, ply steer) with special focus on conicity. High-speed uniformity measurements are also mentioned. The course of tire testing is presented, including cross-section analysis, footprint evaluation, high- and low-speed durability tests, rolling resistance measurement, and bead seating force and pressure assessment, all in relation to customer requirements and homologation standards. Conducted literature review of current researches in the tire industry highlights the growing use of machine learning methods to improve tire manufacturing. The most commonly applied machine learning models in the industry are presented. The research compares multiple linear regression, artificial neural networks (multilayer perceptron) and decision tree-based models (XGBoost, FastTreeRegression, LightGbmRegression). Algorithms were trained on real data from the historical records of tire mass production. The most suitable method was selected using RMSE and R^2 metrics, as well as the operational capabilities of the company. The chosen model was validated across a wider group of tire sizes, representing the production capabilities of the VMI MAXX machines. The study was concluded by presenting the progress of implementation research results within the company's IT system and on the VMI MAXX machine as a tool to support large-scale tire production. Directions for further work and potential effects of implementation continuation are outlined.

1. Wprowadzenie

W 2018 roku w zakładzie Bridgestone w Poznaniu wdrożono nowoczesne maszyny konfekcyjne VMI MAXX, które umożliwiają rejestrację danych wejściowych procesu konfekcji opon. Otworzyło to nowe perspektywy badawcze, związane z możliwością zestawienia parametrów materiałów wprowadzanych do procesu z wynikami pomiarów jednorodności opon. Powstała tym samym możliwość predykcji wielkości opisujących jednorodność wyrobu gotowego z wykorzystaniem nowoczesnych metod uczenia maszynowego. Otwiera to drogę do praktycznego wdrożenia narzędzi analitycznych, które pozwolą na zwiększenie efektywności produkcji, ograniczenie ilości odpadów i podniesienie konkurencyjności przedsiębiorstwa.

Szerszy kontekst naukowy i przemysłowy wskazuje, że dla każdej nowoczesnej organizacji produkcyjnej, niezależnie od branży, istotne znaczenie mają redukcja kosztów oraz wzrost produktywności. W przypadku producentów opon wyzwaniem jest minimalizacja odpadów oraz spełnienie rosnących wymagań środowiskowych i jakościowych. Problem emisji dwutlenku węgla w procesach odzysku energii ze zużytych opon jest szczególnie istotny w kontekście współczesnej polityki klimatycznej. Recykling materiałowy i produktowy, choć intensywnie rozwijany, nie może być jedyną odpowiedzią na wyzwania związane z zagospodarowaniem surowców gumowych. Należy dodać również, że rozwój alternatywnych systemów napędowych i paliw niskoemisyjnych stawia przed przemysłem oponiarskim nowe wymagania w zakresie ograniczania oporów toczenia, co przekłada się na konieczność konstruowania lżejszych i coraz bardziej zaawansowanych technologicznie opon.

Kolejnym aspektem rynkowym są znormalizowane etykiety UE, umożliwiające klientom porównanie kluczowych parametrów opon, takich jak przyczepność na mokrej nawierzchni, efektywność paliwowa czy poziom generowanego hałasu. Świadomi użytkownicy mogą w ten sposób wybierać produkty spełniające ich wymagania w zakresie bezpieczeństwa, ekonomiki eksploatacji oraz komfortu jazdy. Równocześnie intensyfikacja rozwoju pojazdów elektrycznych, związana m.in. z polityką transportu bezemisyjnego Unii Europejskiej (Kamionka, 2023), wymusza opracowywanie nowych konstrukcji ogumienia. Konsekwencją jest konieczność redukcji masy opon poprzez zmniejszanie ich przekroju poprzecznego, co znacząco utrudnia spełnienie stale zastrzanych wymagań producentów samochodów w zakresie fizycznej jednorodności.

Wspomniane wyzwania potwierdzają znaczenie i aktualność podjętej problematyki. Niniejsza rozprawa doktorska wpisuje się w dyscyplinę inżynieria mechaniczna w obszarze

inżynierii produkcji poprzez nowe podejście zastosowania maszyn VMI MAXX, wyposażonych w system monitorowania i rejestracji parametrów materiałowych, który stwarza unikalną okazję do przeprowadzenia pogłębionych badań nad relacjami pomiędzy jakością materiałów wejściowych a jednorodnością gotowego wyrobu. Analiza tych zależności umożliwia bardziej precyzyjne przewidywanie właściwości opon oraz może prowadzić do opracowania nowych metod wspomagających proces decyzyjny w produkcji. Przeprowadzone badania pozwalają również na ocenę poprawności dotychczasowych wytycznych i tolerancji stosowanych w zakładzie oraz otwierają drogę do ich dalszej poprawy.


Dotychczasowe badania oraz przegląd literatury wskazują, że większość prac naukowych koncentruje się na analizie zachowania opon w warunkach eksploatacyjnych. Jest to podejście charakterystyczne również dla rankingów konsumenckich, przeprowadzanych przez ADAC czy Auto Bild. W niewielkim stopniu podejmowane są natomiast kwestie problemów stricte produkcyjnych, w tym zagadnień związanych z osiąganiem wymaganej jednorodności wyrobu. Należy podkreślić, że stożkowatość opon stanowi jeden z najważniejszych parametrów jakościowych w hierarchii problemów produkcyjnych w zakładzie, w którym przeprowadzono niniejsze badania. W literaturze brak jest natomiast doniesień na temat prób wykorzystania danych wejściowych z procesu konfekcji (np. szerokości materiałów czy ich centrowaniu na bębnach) do predykcji wielkości opisujących jednorodność. Luka ta uzasadnia potrzebę realizacji badań i potwierdza ich oryginalność.

Założeniem rozprawy jest opracowanie i wdrożenie modelu uczenia maszynowego, który umożliwi przewidywanie parametrów jednorodności opon na podstawie danych wejściowych z procesu konfekcji, a następnie zastosowanie tego modelu jako narzędzia wspomagającego masową produkcję. Przyjęte podejście ma na celu ograniczenie ilości odpadów, obniżenie kosztów produkcji oraz zwiększenie efektywności całego procesu. Badania oparte zostały na analizie danych historycznych, obejmujących szerokie spektrum rozmiarów opon produkowanych na maszynach VMI MAXX.

Przedmiotem rozważań są zatem: identyfikacja kluczowych elementów procesu konfekcji i możliwości technologicznych maszyn, opracowanie i ocena modeli predykcyjnych opartych na metodach uczenia maszynowego oraz analiza procesów technologicznych wytwarzania opon w celu uzyskania wyników jednorodności mieszczących się w granicach dopuszczalnych limitów. Ostatecznym zamierzeniem jest wypracowanie rozwiązania, które umożliwi fabryce uzyskiwanie produktów spełniających restrykcyjne wymagania producentów samochodów, a tym samym zwiększy konkurencyjność przedsiębiorstwa na rynku globalnym.

2. Budowa opon radialnych

Badania realizowane na potrzeby niniejszej dysertacji zostały przeprowadzone w fabryce Bridgestone w Poznaniu, specjalizującej się w produkcji opon radialnych do samochodów osobowych. W związku z tym w bieżącym rozdziale omówiono komponenty składowe oraz stosowane konstrukcje charakterystyczne dla tego rodzaju opon. Istotnym zagadnieniem, od którego należałoby rozpocząć charakterystykę opon radialnych jest sposób opisu ich rozmiarów, które determinują zarówno proces projektowania, jak i późniejsze zastosowanie, co zostało przedstawione na Rysunku 2.1.



Rysunek 2.1. Opis rozmiarów opon radialnych (opracowanie własne)

Za proces standaryzacji opon i felg na obszarze Europy odpowiada Europejska Organizacja Techniczna ds. Opon i Felg - E.T.R.T.O. (ang. *European Tires and Rims Technical Organization*). Instytucja ta pełni funkcję koordynatora w zakresie opracowywania, wdrażania i aktualizacji norm dotyczących wymiarów opon i felg, a także powiązanych z nimi oznaczeń technicznych. Jej działalność ukierunkowana jest na ujednolicenie parametrów konstrukcyjnych, co umożliwia zapewnienie kompatybilności oraz bezpieczeństwa eksploatacji opon i felg tworzących zespół koła. Odnosząc się do Rysunku 2.1. oraz (ETRTO, 2025):

- 1) Szerokość przekroju SW (ang. *section width*) – jej znaczenie zostało wyjaśnione w Rozdziale 4.4.1., wyraża się ją w [mm].
- 2) Wysokość profilu (ang. *aspect ratio*) [%] – wyraża wysokość boku opony w stosunku do jej szerokości. Procentowe określanie profilu opony stanowi najbardziej

funkcjonalny i powszechnie akceptowany sposób jego zapisu. Stosowany obecnie system przedziałów pięcioprocentowych umożliwia precyzyjną klasyfikację rozmiarów opon poprzez podział całej ich populacji na kilkanaście grup rozmiarowych (dla danej średnicy felgi).

- 3) „R” – informuje o radialnej strukturze opony, co oznacza, że warstwy jej kordów tekstylnych ułożone są promieniowo (radialnie), czyli prostopadle do osi obrotu koła. Dla porównania, opony diagonalne posiadają w tym miejscu symbol „D” lub „-”.
- 4) Średnica felgi [cal] – średnica osadzenia opony na feldze.
- 5) Indeks nośności – kod numeryczny związany z maksymalnym obciążeniem, jakie opona może przenosić (z pewnymi wyjątkami przy prędkościach powyżej 210[km/h]) przy prędkości wskazanej przez indeks prędkości, w warunkach eksploatacyjnych określonych przez producenta opony.
- 6) Indeks prędkości – kod literowy wskazujący maksymalną prędkość, przy której opona może przenosić obciążenie odpowiadające jej indeksowi nośności (z pewnymi wyjątkami przy prędkościach powyżej 210[km/h]) w warunkach eksploatacyjnych określonych przez producenta opony.

Bez względu na konstrukcję lub zastosowanie, każda opona radialna musi spełniać podstawowy zestaw funkcji (Rodgers i Waddell, 2005):


- 1) Zapewniać nośność.
- 2) Gwarantować amortyzację i tłumienie drgań.
- 3) Przenosić moment napędowy i hamujący.
- 4) Zapewniać przekazanie siły bocznej (do pokonywania zakrętów).
- 5) Zapewniać stabilność wymiarową.
- 6) Wykazywać się odpornością na ścieranie.
- 7) Generować reakcję zadaną przez układ kierowniczy.
- 8) Charakteryzować się niskimi oporami toczenia.
- 9) Zapewniać minimalny hałas i minimalne drgania.
- 10) Cechować się trwałością i przewidywalnością pracy przez cały założony okres eksploatacji.

Opony są produktem, spełniającym wszystkie powyższe funkcje w głównej mierze dzięki zastosowaniu gumy, która charakteryzuje się znakomitymi własnościami tłumiącymi,

elastycznymi oraz unikalną zdolnością do odkształcania się i powrotu do pierwotnego kształtu.

Podstawowy podział opony na 4 obszary (Rysunek 2.2.): bieżnika, barku, boku i drutówki umożliwia skuteczne zarządzanie całym cyklem życia ogumienia – od projektu i produkcji, przez eksploatację, aż po recykling. Każdy z obszarów ma do spełnienia inne funkcje:

- 1) Obszar bieżnika – kontakt z podłożem, zapewnienie trakcji, odporności na ścieranie i odprowadzania wody (tzw. aquaplaning).
- 2) Obszar barku – stabilizacja opony w zakrętach, zapewnienie odporności na obciążenia poprzeczne.
- 3) Obszar boku – ochrona kordu tekstylnego (osnowy) przed uszkodzeniami mechanicznymi i warunkami atmosferycznymi, tłumienie wibracji, przekazywanie sił bocznych.
- 4) Obszar drutówki – zapewnienie szczelności i stabilności połączenia z felgą, przenoszenie obciążeń osiowych i promieniowych.




Rysunek 2.2. Obszary opony radialnej dedykowanej do aut osobowych (opracowanie własne)

Konstrukcja nowego rozmiaru opony (Rysunek 2.3.) dobierana jest na podstawie:

- 1) Planowanej szerokości i profilu.
- 2) Zastosowania oraz wymagań klienta dotyczących warunków jezdnych.
- 3) Ograniczeń wynikających z możliwości technologicznych oprzyrządowania maszyny konfekcyjnej.

Stosowane współcześnie rozwiązania konstrukcyjne można sklasyfikować według sposobu wzajemnego ułożenia bieżnika i boku opony (Rysunek 3.3.). Dwie główne konstrukcje, to:

- 1) SOT (*Sidewall Over Tread*) – konfiguracja, w której boki są wywijane na bieżnik w taki sposób, aby stworzyły połączenie z minibokami bieżnika, zapewniając korzystne warunki adhezji po zarolowaniu na zimno podczas procesu konfekcji;
- 2) TOS (*Tread Over Sidewall*) – uzyskany w wyniku odwrotnej do przedstawionej powyżej sekwencji procesu konfekcji, w której bieżnik jest aplikowany po uprzednim wywinięciu boków, co skutkuje ich przykryciem przez pakiet. Specyficzną odmianą konstrukcji TOS jest konstrukcja RGT (*Rim Guard*), charakteryzująca się minibokiem sięgającym niemal do wierzchołka rantu ochronnego felgi. Ze względu na jej sztywność i wytrzymałość stosuje się ją do szerokich opon z niskim profilem (20-35%) i wysokim indeksem prędkości (W, Y, (Y)) o zastosowaniu sportowym (tzw. UHP – *ultra high performance*).



Rysunek 3.3. Najczęściej stosowane konstrukcje opon (opracowanie własne)

Opony posiadające wysokie profile (55-80%) mogą być produkowane zarówno jako TOS-y, jak i SOT-y. Mając na uwadze obniżenie kosztów produkcji, zazwyczaj dąży się do wyboru tej drugiej opcji – cykl SOT jest zdecydowanie krótszy – opona zostaje

złożona w całość w trakcie jednego rolowania. W przypadku konstrukcji TOS należy najpierw zarolować boki, natomiast po nałożeniu pakietu dochodzi do osobnego rolowania bieżnika (szerszy opis konfekcji opon zamieszczono w Rozdziale 3.2.). Z tego względu, opony średnioprofilowe (40-50%) produkowane są najczęściej z wykorzystaniem konstrukcji SOT.

Do obowiązkowych komponentów składowych opon radialnych dedykowanych do samochodów osobowych należą:

- 1) Bieżnik – TT (*ang. top tread*) – uzyskiwany w wyniku procesu wytłaczania czteroślimakowego, w którym każdy ślimak odpowiada za inny obszar jego przekroju poprzecznego. W skład bieżnika wchodzi:
 - a) Kapa bieżnika (*ang. cap*) – wykonana z mieszanki gumowej odpowiednio dobranej do zastosowania (typ pojazdu) oraz warunków eksploatacji opony (letnia, zimowa, całoroczna).
 - b) Warstwa podbieżnikowa – UT (*ang. undertread*) – jej zadaniem jest efektywne odprowadzanie ciepła generowanego wskutek tarcia wewnętrznego podczas jazdy.
 - c) Miniboki – MSW (*ang. minisidewalls*) – wykonane z mieszanki gumowej zbliżonej składem chemicznym do mieszanki boku, co umożliwia uzyskanie połączenia bieżnik–bok „na zimno” w procesie konfekcji, które ulega dalszemu umocnieniu podczas procesu wulkanizacji.
 - d) Antena – ANT (*ang. antenna*) – wykonana z przewodzącej mieszanki gumowej, odpowiadająca za odprowadzanie ładunków elektrostatycznych podczas eksploatacji opony.
- 2) Warstwa spiralna – SL (*ang. spiral layer / CP – ang. cap ply*) – nawijana z wąskich pasków kalandrowanego kordu (PET, kevlar, nylon, aramid). Zwykle stosuje się jedną lub dwie warstwy, najczęściej z dodatkowymi paskami nawiniętymi na brzegach – ich szerokość kontrolowana jest poprzez ustawienie posuwu (prędkości przesunięcia lewo-prawo [mm / obrót]) i liczby obrotów bębna BT.
- 3) Opasania – TP (*ang. tread plies*, często nazywane także „*breakers*”) – składają się z kalandrowanego kordu stalowego, którego wiązki ułożone są pod określonym kątem (57–67°), co bezpośrednio wpływa na właściwości jezdne opony. W celu sterowania tymi właściwościami istnieje możliwość doboru drutów o różnej grubości oraz o różnej ilości drutów w pojedynczej wiązce. Brzegi opasań zakończone są tzw. gumą krawędziową (*ang. edge gum*), która ma za zadanie chronić sąsiadujące

z opasaniami materiały przed wystającymi z nich drutami, aby w trakcie eksploatacji nie doszło do ich przecięcia, co mogłoby spowodować nagłe zniszczenie opony po uzyskaniu przez nią niewielkiego przebiegu.

- 4) Osnowa – BP (*ang. body ply*) – kalandrowany kord z PET lub wiskozy, którego szerokość dedykowana do danej opony zależy od wysokości jej profilu, szerokości oraz konstrukcji. Długość tego komponentu sprzężona jest natomiast z jej całem. Na osnowie rozmieszczane są paski gumowe (tzw. *squeegee*), których konfiguracja oraz szerokość są projektowane tak, aby pokrywać krawędzie zakończeń materiałów i wzmacniać wewnętrzną stronę obszaru barkowego, który jest najbardziej obciążony zarówno podczas formowania, jak i eksploatacji opony. Szczególnie istotnym elementem jest TPI (*ang. tread ply insert*), zwany również BUC (*ang. belt under cushion*), stanowiący ochronę osnowy przed przecieraniem przez krawędzie opasań w trakcie ruchu opony. Zastosowanie konstrukcji SOT zawsze implikuje obecność TPI, natomiast w konstrukcji TOS pod opasaniami znajduje się końcówka boku, toteż TPI jest zbędny. Opony do samochodów osobowych zazwyczaj zawierają jedną lub dwie osnowy – stąd rodzi się kolejny podział konstrukcyjny na opony jednoosnowowe lub dwuosnowowe. Dobór odpowiedniego kordu osnowy/osnów umożliwia kształtowanie sztywności, wytrzymałości oraz właściwości jezdnych gotowego wyrobu. W istotnej mierze jest również powiązany z wymaganym indeksem nośności opony.
- 5) Skrzydełko – BB (*ang. bead bundle*) – składające się z:
 - a) Drutówki (*ang. bead*) – wykonanej ze stalowego drutu, nawiniętego w określonej konfiguracji (zadana liczba warstw i kolumn w przekroju wiązki) i owiniętego taśmą.
 - b) Wypełniacza drutówki BF (*ang. bead filler*) – aplikowanego „na ciepło” na przygotowanej wcześniej drutówce paska twardej gumy o przekroju trójkątnym, wzmacniającego obszar drutówki.
- 6) Bok – SW (*ang. sidewall*) – najczęściej wytłaczany z zastosowaniem dwóch mieszanek:
 - a) AGS (*ang. abrasive gum strip*) – twarda mieszanka chroniąca obszar drutówki przed przetarciem przez obręcz felgi.
 - b) Mieszanka boku – mieszanka opracowana z myślą o odporności na pękanie spowodowane czynnikami środowiskowymi, takimi jak ozon, tlen, promieniowanie UV czy temperatura.

- 7) Wykładzina wewnętrzna – zapewnia szczelność w oponach bezdętkowych dzięki zastosowaniu mieszanki butylowej o niskiej przepuszczalności gazów.

Do opcjonalnych komponentów składowych opon należą:

1) Wzmocnienia tekstylne:

- a) Chafer – CCH (*ang. canvas chafer*) – kalandrowany, ułożony krzyżowo kord tekstylny wzmacniający obszar drutowki. Stosowany głównie w oponach typu runflat, chroniąc felgę i oponę podczas jazdy awaryjnej (na przebitej oponie).
- b) Flipper – FL – kalandrowany kord (PET lub Kevlar), ułożony pod kątem 45°, stosowany w celu usztywnienia obszaru drutowki i/lub boku, najczęściej w oponach UHP, gdyż jego obecność poprawia właściwości jezdne pojazdu.

- 2) Wzmocnienia gumowe – najczęściej stosowaną formą jest wkładka runflatowa RFI (*ang. run flat insert*), uzyskiwana przez wytłaczanie twardej mieszanki gumowej (Xingyu i in., 2021). Zgodnie z deklaracją producenta, zastosowana w obszarze boku opony umożliwia pokonanie dystansu do 80[km] z prędkością do 80[km/h] po przebiciu opony.

Budowa typowej opony radialnej (bez dodatkowych wzmocnień tekstylnych i gumowych) została przedstawiona na Rysunku 2.4.



Rysunek 2.4. Komponenty składowe opony (opracowanie własne)

Interdyscyplinarny charakter projektowania opon wymaga integracji wiedzy z zakresu wytwarzania polimerów, inżynierii materiałowej oraz mechaniki. Ostateczne właściwości opony wynikają z synergicznego działania wszystkich komponentów oraz precyzyjnego doboru i kontroli parametrów technologicznych podczas procesu produkcyjnego.

3. Proces produkcji opon radialnych

W przedsiębiorstwie, w którym realizowano badania na potrzeby niniejszej pracy doktorskiej, prowadzona jest wielkoseryjna produkcja na poziomie około 30 tys. opon dziennie, co wymaga zatrudnienia około 2000 pracowników. Do masowej produkcji wdrożonych jest ponad 500 różnych rozmiarów opon w zakresie od 15 do 24 cali. Zakład zajmuje powierzchnię 260 tys. m².

Proces produkcji opon zawsze składa się z czterech głównych etapów:


- 1) Przygotowanie materiałów.
- 2) Konfekcja opon surowych.
- 3) Wulkanizacja.
- 4) Inspekcja końcowa.

Ze względu na wdrożeniowy charakter niniejszej rozprawy doktorskiej, w tym rozdziale proces produkcji opon zostanie przedstawiony na podstawie jego faktycznego przebiegu w zakładzie Bridgestone Poznań (Rysunek 3.1.), w celu precyzyjnego umiejscowienia obszaru przeprowadzonych badań.

3.1 Przygotowanie materiałów


Proces produkcji opon, zobrazowany na Rysunku 3.1., rozpoczyna się w Magazynie Surowców, gdzie każda dostawa poddawana jest kontroli jakościowej. Miksery, będące sercem Działu Walcowni, odpowiadają za wytwarzanie wszystkich mieszanek gumowych stosowanych w zakładzie produkcyjnym. Od współczesnych mieszanek gumowych wymaga się stabilności właściwości lepkością (co warunkuje ich przetwarzalność), relatywnie krótkiego czasu wulkanizacji, a jednocześnie – zachowania satysfakcjonujących właściwości mechanicznych wyrobu finalnego (Tardiff i in., 2017). Osiągnięcie tego kompromisu możliwe jest dzięki odpowiedniemu doborowi składu chemicznego mieszanek oraz precyzyjnemu sterowaniu procesem ich mieszania. W celu zapewnienia wysokiej jednorodności mieszanki gumowej, Bridgestone Poznań wyposażone jest w dwa miksery tandemowe, które są zaawansowanym i rzadkim rozwiązaniem stosowanym w przemyśle oponiarskim w skali europejskiej. Mikser tandemowy to rodzaj miksera składającego się z dwóch zespołów mieszadeł zazębiających się, rozmieszczonych w układzie górnym i dolnym. Górny mikser służy do mieszania wsadowego oraz mieszania w stałej temperaturze. Dolny mikser został zaprojektowany do mieszania w stałej temperaturze i charakteryzuje się doskonałą funkcją

mieszania rozpraszającego, precyzyjną kontrolą temperatury, zoptymalizowaną wentylacją oraz dużą powierzchnią chłodzenia. Produktem pracy miksera jest surowa, spaletyzowana guma, która stanowi surowiec dla wycłaczarek, kalandra oraz maszyn do produkcji opasań i skrzydełek. Poszczególne miksery dedykowane są określonym grupom mieszanek o zbliżonym składzie chemicznym, co wynika z czasochłonności procesu czyszczenia komory mieszania i walców.



Rysunek 3.1. Proces produkcji opon w Bridgestone Poznań (opracowanie własne)

W procesie wytłaczania produkowane są komponenty takie jak: bieznik, bok, wkładka runflatowa oraz wykładzina wewnętrzna. Kształt przekroju poprzecznego oraz rozmieszczenie mieszanek gumowych w surowych profilach wytłaczanych nadawany jest przez ustniki i wkładki wytłaczarki (Costa, 2017). Przykładowe kontury bieznika i boku zostały zaprezentowane na Rysunkach 3.2. i 3.3.



Rysunek 3.2. Przykładowy przekrój surowego bieznika (opracowanie własne)


Bezpośrednio po wytłaczaniu na bieznik nanoszone są linie kolorowe, których rozmieszczenie (pozycja względem linii centralnej) i barwa są unikalne dla każdego rozmiaru opony. Linie te ułatwiają automatyczne sortowanie opon na zautomatyzowanej linii montażu pojazdów. Bieznik jest nawijany na duże szpule z przekładkami minimalizującymi jego deformację podczas transportu. Boki, wkładka runflatowa oraz wykładzina wewnętrzna umieszczane są na specjalistycznych wózkach zapewniających płynne podłączenie tych komponentów do maszyny konfekcyjnej. Cykliczna kontrola wymiarowa (Duvar i in., 2012) profilu poprzecznego wytłoczonych prefabrykatów (z wyjątkiem wykładziny wewnętrznej) realizowana jest w Konturowni. Na podstawie wyników tej kontroli podejmowana jest decyzja o dopuszczeniu materiału do dalszej produkcji masowej.



Rysunek 3.3. Przykładowy przekrój surowego boku (opracowanie własne)

Opasania wytwarzane są na maszynie Bexter, która pobiera drut stalowy ze szpularnika, nadaje mu odpowiedni kąt, pokrywa mieszanką gumową, przycina do wymaganej szerokości oraz nakłada paski gumy krawędziowej. Gotowe opasania, podobnie jak bieznik, nawijane są na duże szpule z przekładkami i w takiej postaci transportowane do maszyny konfekcyjnej.

Kordy tekstylne poddawane są procesowi kalandrowania, w trakcie którego pokrywa się je odpowiednią mieszanką gumową, zgodnie z wymaganiami dla danego rodzaju kordu. Na świeżo powstałą warstwę gumy nanoszone są w określonych odstępach nitki ułatwiające odprowadzenie powietrza z wnętrza opony w trakcie konfekcji i wulkanizacji (nie dotyczy to kordów dedykowanych na warstwę spiralną). Kalandrowane kordy nawijane są w duże baloty i przekazywane do Działu Cięcia, gdzie nadawane są im odpowiednie szerokości dla osnowy, flippera, chafera oraz spirali. W przypadku osnów proces cięcia jest zintegrowany z nakładaniem squeegee i TPI zgodnie z zadaną specyfikacją. Przykładowy layout osnowy został przedstawiony na Rysunku 3.4. Chafer, flipper i spiral nawijane są na małe szpule, natomiast osnowy transportowane są na dedykowanych wózkach, zapewniających kompatybilność z maszyną konfekcyjną.




Rysunek 3.4. Przykładowy schemat rozmieszczenia pasków gumowych na osnowie (opracowanie własne)

Owinięte taśmą drutówki, umieszczane są na maszynie RTB-DE, która wytłacza wypełniacz drutówki o określonych w specyfikacji jego konturu: wysokości, szerokości podstawy i mieszance gumowej. Następnie łączy oba prefabrykaty, tworząc skrzydełka. Gotowe skrzydełka umieszczane są na specjalnych separatorach, co zapobiega ich wzajemnemu sklejeniu, deformacji oraz zanieczyszczeniu ciałami obcymi.

3.2 Konfekcja opon na maszynie VMI MAXX

Proces konfekcji realizowany na maszynach VMI MAXX, składa się z dwóch zasadniczych faz i służy połączeniu wszystkich wcześniej opisanych komponentów powstałych na etapie przygotowania materiałów w odpowiedniej sekwencji, zgodnej z kartą procesu technologicznego. Dzięki zastosowanym technologiom maszyny VMI MAXX pracują w trybie automatycznym – od operatora wymagają jedynie uzupełniania materiałów do produkcji opon oraz reakcji na bieżące komunikaty. Charakteryzują się również możliwością rejestracji danych w trybie ciągłym dla każdej wyprodukowanej opony tj. długość i szerokość używanych

materiałów, centrowanie materiałów na bębnach, jakość wykonanych złącz oraz bicie promieniowe opony surowej. Budowa maszyny VMI MAXX została przedstawiona na Rysunku 3.5.



Rysunek 3.5. Budowa zespołu maszyny konfekcyjnej VMI MAXX (materiały własne przedsiębiorstwa)

Elementy składowe maszyny to:

- 1) System linii lasera (strona B&T) – system sterowania automatycznie ustawia linie lasera tak, aby padały na bęben B&T zgodnie z wyspecyfikowaną szerokością materiału nakładanego w danym etapie produkcji.
- 2) Urządzenie do podnoszenia bębna – umożliwia wymianę/demontaż części bębna B&T i bębna karkasu. Jest zamontowane pod ramą bazową, która z kolei jest przymocowana w górnej części maszyny.
- 3) Jednostka zdejmowania opony surowej – służy do usuwania kompletnej opony surowej z pierścienia transferu i przekazuje ją na przednią stronę maszyny.
- 4) Pierścień transferowy – tzw. transferring, jest podzielony na 8 segmentów. Każdy z nich można przesuwac promieniowo za pomocą siłowników pneumatycznych. Siłowniki są wyposażone w urządzenie zaciskające – gdy segment zetknie się z pakietem B&T, siłownik pneumatyczny zaciska pakiet B&T i utrzymuje go tak długo, jak to konieczne.


Aby zapewnić współosiowość, każdy segment zaciska pakiet B&T z taką samą siłą, niezależnie od średnicy pakietu. Pierścień transferowy samoczynnie dostosowuje się do całkowitej średnicy opony.

- 5) Moduł aplikatora skrzydełek – współpracuje z zespołem robota, który umieszcza na nim skrzydełka. Moduł aplikatora natomiast przytrzymuje drutówkę podczas wklejania jej w karkas.
- 6) Monitor zapasu materiałów – wyświetla informacje o produkowanym aktualnie rozmiarze opon oraz zapasie używanych materiałów.
- 7) Zszywarka kombi – odpowiada za wykonywanie złącza bieźnika.
- 8) System linii lasera (strona karkasu) – system sterowania automatycznie ustawia linię lasera tak, aby padały na bęben karkasu zgodnie z wyspecyfikowaną szerokością materiału nakładanego w danym etapie produkcji.
- 9) Bęben karkasu – na nim odbywa się I faza konfekcji.
- 10) Monitor karkasu CCMO (*ang. carcass monitor*) - służy do sprawdzania czy złącza materiałów są zgodne ze zdefiniowaną specyfikacją. Może kontrolować złącza: materiału zespołu wstępnego PA (który tworzą boki i wykładzina wewnętrzna), materiału osnowy / osnów (BP1/BP2) i materiału flippera (FL).
- 11) Obudowa karkasu – umieszczone w niej podzespoły odpowiadają za sterowanie i ruch bębna karkasu.
- 12) Łoże maszyny (strona karkasu) - przeznaczone do przesuwania następujących zespołów: obudowy karkasu, wózka całego modułu drutówki, zszywarki kombi.
- 13) Zszywarka złączy PA – odpowiada za wykonanie szczelnego złącza PA.
- 14) Panel interfejsu HMI – pozwala na bieżące ustawianie parametrów i podgląd pomiarów przeprowadzanych przez maszynę.
- 15) Moduł wózka skrzydełek – główną funkcją wózka drutówki jest precyzyjne ustawienie drutówek na pakiecie karkasu zgodnie z zadaniem rozstawem drutówek, który stanowi najważniejszy parametr procesu konfekcji.
- 16) Platforma opony surowej – miejsce inspekcji opony surowej przez operatora konfekcji.
- 17) Łoże maszyny (strona BT) – służy do przesuwania bębna B&T.
- 18) Bęben B&T – na nim odbywa się II faza konfekcji.
- 19) Monitor opasania i bieźnika BTMO (*ang. breaker & tread monitor*) - służy do kontrolowania następujących kwestii: ocena złączy materiału opasań i bieźnika, wykrywanie obecności materiału opasań i bieźnika, pomiar szerokości i centrowanie materiału bieźnika, wykrywanie uszkodzeń materiału opasań i bieźnika.

20) Obudowa B&T – umieszczone w niej podzespoły odpowiadają za sterowanie i ruch bębna B&T.

Systemy prowadzenia materiałów odpowiedzialne za rejestrację danych, są podzespołami monitora karkasu (system prowadzenia karkasu) oraz monitora B&T (systemy prowadzenia opasań i bieznika). Zasada ich działania oraz sposób zapisu danych zostały szczegółowo opisane w Rozdziale 7.1.1.

Za transport (w obrębie maszyny) i aplikację (na dany bęben) poszczególnych materiałów niezbędnych do przeprowadzenia procesu konfekcji, odpowiadają następujące podzespoły (Rysunek 3.6.).



Rysunek 3.6. Zespół maszyny konfekcyjnej VMI MAXX wraz z peryferiami (materiały własne przedsiębiorstwa)





Podzespołami oznaczonymi na Rysunku 3.6. są:

- 1) Zespół maszyny konfekcyjnej.
- 2) Serwer flippera.
- 3) Serwer wkładki RFI.
- 4) Serwer chafera.
- 5) Automatyczny serwer karkasu – odpowiada za łączenie boków i wykładziny wewnętrznej w zespół PA, podaje go wraz z osnową / osnowami na bęben karkasu.
- 6) Serwer bieźnika.
- 7) Automatyczny serwer opasania.
- 8) Robot – jego zadaniem jest pobranie skrzydełka z separatora (z wózka na którym skrzydełka przedzielone separatorami przyjechały z Działu Przygotowania Materiałów) i założenie go na moduł aplikatora skrzydełek.
- 9) Serwer spirala wraz z kompensatorem.

Przebieg procesu konfekcji dla konstrukcji SOT i TOS został objaśniony w Tabelach 3.1. i 3.2.

Tabela 3.1. Przebieg konfekcji dla konstrukcji TOS (opracowanie własne na podstawie materiałów własnych przedsiębiorstwa)

Krok	Opis	Schemat
1	Krawędź początku PA (boki + wykładzina), czyli A (C+B) jest odbierana przez listwę przytrzymującą na bębnie i poprzez obrót bębna karkasu następuje aplikacja PA.	
2	Osnowa 1 [D] (i opcjonalnie osnowa 2 [E]) poprzez obrót bębna karkasu są aplikowane na PA.	
3	Moduł wózka skrzydełek umieszcza skrzydełka na bębnie karkasu [F].	

4	Zamki drutówki [G] blokują drutówki.	
5	Bęben karkasu zjeżdża się do szerokości wywijania. Barki [H] przesuwają się w górę, na skutek gdy karkas jest pompowany do ciśnienia wywijania.	
6	Palce wywijające [I] zsuwają się i wywijają wystający poza drutówkami materiał boków i osnowy.	
7	Bęben karkasu rozsuwa się do szerokości wstępnego formowania, a do karkasu jest podawane ciśnienie wstępnego formowania.	
8	Karkas [J] przesuwają się pod pakiet B&T oczekujący w transferringu.	
9	Bęben karkasu zsuwa się i wkleja karkas w pakiet B&T.	
10	Segmenty transferringu zwalniają pakiet B&T.	














11	Dochodzi do docisku pakietu do karkasu na skutek działania rolki centralnej pracującej z zewnątrz oraz wewnętrznego ciśnienia karkasu.	
12	Odbywa się rolowanie bieznika.	
13	Segmenty transferringu podtrzymują oponę surową [L]. Zamki drutowki zwalniają drutowkę. Jednostka zdejmowania opony surowej [K] chwyta oponę surową.	
14	Segmenty transferringu zwalniają oponę surową [L]. Opona surowa jest odbierana przez jednostkę usuwania opony surowej [K].	

Tabela 3.2. Przebieg konfekcji dla konstrukcji SOT (opracowanie własne na podstawie materiałów własnych przedsiębiorstwa)

Krok	Opis	Schemat
1	Krawędź początku PA (boki + wykładzina), czyli A (C+B) jest odbierana przez listwę przytrzymującą na bębnie i poprzez obrót bębna karkasu następuje aplikacja PA.	
2	Osnowa 1 [D] (i opcjonalnie osnowa 2 [E]) poprzez obrót bębna karkasu są aplikowane na PA.	

3	Moduł wózka skrzydełek umieszcza skrzydełka na bębnie karkasu [F].	
4	Zamki drutowki [G] blokują drutowki.	
5	Bęben karkasu zjeżdża się do szerokości wywijania. Barki [H] przesuwają się w górę, na skutek gdy karkas jest pompowany do ciśnienia wywijania.	
6	Karkas [I] przesuwa się pod pakiet B&T oczekujący w transferringu.	
7	Bęben karkasu zsuwa się i wkleja karkas w pakiet B&T.	
8	Segmenty transferringu zwalniają pakiet B&T.	
9	Dochodzi do docisku pakietu do karkasu na skutek działania rolki centralnej pracującej z zewnątrz oraz wewnętrznego ciśnienia karkasu.	

10	Odbywa się rolowanie bieżnika.	
11	Palce wywijające [J] zsuwają się i wywijają wystający poza drutówkami materiał boków i osnowy.	
12	Segmenty transferringu podtrzymują oponę surową [L]. Zamki drutówki zwalniają drutówkę. Jednostka zdejmowania opony surowej [K] chwyta oponę surową.	
13	Segmenty transferringu zwalniają oponę surową [L]. Opona surowa jest odbierana przez jednostkę usuwania opony surowej [K].	

Opisując specyficzny przebieg procesu konfekcji opon, wyszczególnia się jego dwie zasadnicze fazy. Podczas I fazy na bębnie karkasu powstaje karkas opony, na który składają się: boki, wykładzina wewnętrzna, osnowa (lub osnowy), skrzydełka i opcjonalnie dokładane są tekstylne (chafer, flipper) lub gumowe (wkładka runflatowa) materiały wzmacniające. Tymczasem II faza procesu konfekcji realizowana jest na bębnie B&T (*ang. band transfer drum*). Rozpoczyna się od nałożenia pierwszego i drugiego opasania. Następnie nawijana jest warstwa spiralna, w taki sposób, aby jej krawędzie zakrywały krawędzie szerszego opasania pierwszego. Kolejnym etapem jest aplikacja bieżnika, którego złącze dociskane jest przez rolkę Multidisc – urządzenie składające się ze stalowych krążków umożliwiających precyzyjne sterowanie siłą docisku w wybranym segmencie na szerokości bieżnika. Efektem II fazy jest powstanie pakietu B&T. Obie fazy (przygotowanie karkasu i pakietu B&T) odbywają się na maszynie konfekcyjnej równolegle, dlatego nie nazywa się ich np. etapami (czyli czynnościami następującymi jedna po drugiej). II faza trwa zdecydowanie krócej – pakiet

B&T „oczekuje” w transferringu na karkas. Z tego względu, w tym czasie ważne jest jego równomierne podparcie w celu uniknięcia deformacji. Największym wyzwaniem, a jednocześnie głównym zamysłem procesu konfekcji jest budowanie opony z materiałów złożonych z niezwulkanizowanej, miękkiej mieszanki gumowej bez zmiany ich pierwotnego kształtu nadanego na etapie przygotowania.

Po przygotowaniu karkasu i pakietu B&T, maszyna konfekcyjna przechodzi do etapu tzw. formowania opony surowej, który stanowi szereg operacji począwszy od kroku 4, zarówno dla konstrukcji TOS, jaki i SOT wymienionych w Tabelach 3.1 i 3.2.

Na zakończenie procesu konfekcji robot automatycznie nanosi indywidualny kod paskowy na obszar drutówki opony, w określonej odległości od złącza boku. Gotowa opona surowa (GT – *ang. green tire*) zostaje umieszczona przez operatora konfekcji na wózku (liczba opon na wozie zależy od ich gabarytu) lub przez automatyczny system wewnętrznego transportu surowych opon (funkcjonuje już dla części maszyn VMI MAXX), po czym przekazywana jest do Działu Wulkanizacji.


3.3 Wulkanizacja opon

Przed rozpoczęciem procesu wulkanizacji, na wewnętrzną powierzchnię opony surowej (od strony wykładziny wewnętrznej) aplikowany jest środek antyadhezyjny – zawiesina miki lub silikon – mający na celu zapobieżenie przywieraniu opony do membrany wulkanizacyjnej.

Funkcją membrany wulkanizacyjnej jest odpowiednie dociśnięcie opony surowej do formy wulkanizacyjnej zgodnie z zadaniem ciśnieniem oraz odprowadzenie powietrza z wnętrza opony w trakcie trwania procesu. Pęcherze powietrza zalegające pomiędzy oponą surową a membraną są powodem powstawania defektów, np. ubytków wykładziny wewnętrznej i przemieszczenia nitek osnowy. W celu eliminacji powietrza z tego obszaru, membrana jest precyzyjnie dobierana do gabarytu danej opony i dodatkowo posiada dopasowaną fakturę umożliwiającą ucieczkę gazów. Zazwyczaj osiągane jest to poprzez rozmieszczone promieniowo rowki, których głębokość wzrasta w kierunku od centrum do barku opony (Rysunek 3.7.). Faktura wykładziny wewnętrznej w oponie zwulkanizowanej jest negatywem wzoru użytej membrany wulkanizacyjnej.

Kluczową rolą wulkanizacji w procesie produkcji opon jest osiągnięcie odpowiedniego stopnia usieciowania mieszanki gumowej (wytworzenie mostków siarczkowych), zapewniając jej finalne właściwości mechaniczne oraz nadaniu oponie surowej ostatecznej geometrii (Zhang i in., 2016). W trakcie tego procesu odwzorowywana jest rzeźba bieżnika, stamping (oznaczenia na boku opony) oraz kształt ścian bocznych. Najistotniejszymi parametrami procesu

wulkanizacji są: ciśnienie, czas i temperatura. Ich właściwy dobór zapewnia jednolite i kompletne usieciowanie mieszanki gumowej w całym przekroju opony (Wang i in., 2012).




Rysunek 3.7. Faktury membran wulkanizacyjnych stosowane przez producentów opon tj.:

1 – Continental, 2 – Michelin, 3 – Yokohama, 4 – Hankook (opracowanie własne)

Początkowo opona surowa zostaje odłożona przez operatora na stół pozycjonujący prasy wulkanizacyjnej (Yu i in., 2021), w miejscu przeznaczonym do pobrania przez przenośnik załadowniczy. Faza kształtowania rozpoczyna się od umieszczenia opony na membranie wulkanizacyjnej, do której podawana jest para wodna pod ciśnieniem kształtowania – służy to wstępnemu naprężeniu i rozciągnięciu opony, aby wyeliminować deformacje powstałe podczas magazynowania na wozie od momentu konfekcji. W tej fazie rejestrowane jest jedynie ciśnienie, czujnikiem umiejscowionym w membranie wulkanizacyjnej. W kolejnym kroku – czyli w fazie zasadniczej wulkanizacji – uprzednio rozgrzana forma wulkanizacyjna zamyka się na oponie, a do wnętrza membrany wtłaczane jest wysokie ciśnienie, które zapewnia równomierne dociskanie surowej opony do powierzchni formy (Rysunek 3.8.). Uskok na wykresie pomiędzy fazami wynika z przejścia na rejestrację ciśnienia przez czujnik

umieszczony w formie. Od tego momentu ciągły zapis temperatury rozpoczyna również termopara, osadzona także w formie wulkanizacyjnej.



Rysunek 3.8. Zmiana temperatury i ciśnienia w czasie przykładowego cyklu procesu wulkanizacji
(opracowanie własne)

Po zakończeniu procesu i rozformowaniu, zwulkanizowane opony – CT (*ang. cured tires*) – przekazywane są na taśmociąg transportujący je do stanowiska trymowania. Na tym etapie następuje maszynowe usuwanie wypływek – pozostałości gumy w miejscach odpowietrzników formy. Trymowanie jest bardzo ograniczone i przyspieszone w przypadku form wykorzystujących technologię spring ventów (samozamykających się odpowietrzników sprężynowych) (Stinga i in., 2020).

Dla niektórych rozmiarów opon przewidziana jest dodatkowa faza stabilizacji PCI (*ang. post curing inflator*), realizowana bezpośrednio po zakończeniu wulkanizacji. Polega ona na swobodnym chłodzeniu opony w temperaturze otoczenia przy jednoczesnym aplikowaniu do jej wnętrza ciśnienia za pośrednictwem membrany. Stabilizacja zapobiega powstawaniu deformacji (w szczególności zapadaniu się ścian bocznych), a ponadto relaksacja materiałów przebiega w tym przypadku w warunkach kontrolowanych, co wpływa korzystnie na wybrane właściwości użytkowe gotowego wyrobu.

Następnie opony trafiają do Działu Inspekcji Końcowej FI (*ang. Final Inspection*), gdzie przechodzą szczegółową kontrolę zgodności ze specyfikacją techniczną.

3.4 Inspekcja końcowa

Ze względu na wysokie wymagania bezpieczeństwa stawiane przez rynek motoryzacyjny, wszystkie opony opuszczające zakład produkcyjny podlegają obowiązkowej inspekcji końcowej. Proces ten składa się z trzech podstawowych etapów kontroli jakości opon zwulkanizowanych:

- 1) Wykrywanie defektów metodą rentgenowską (*ang. X-ray*) – na tym etapie stosowane są systemy obrazowania radiograficznego służące do detekcji ciał obcych znajdujących się w objętości opony. Ich obecność stanowi istotne zagrożenie dla bezpieczeństwa w czasie eksploatacji, ponieważ może prowadzić do niekontrolowanego przebicia opony.
- 2) Pomiar wielkości opisujących jednorodność – przeprowadzany na maszynach Rim Flow oraz TUO (*Tire Uniformity Grading Machine*), która została zaprezentowana na Rysunku 3.9. Jednorodność fizyczna jest jednym z aspektów jakościowych, świadczącym o jednolitej strukturze opony, który jednocześnie stanowi miarę zdolności opony do płynnej pracy pozbawionej wibracji (Gent i Walter, 2006). Wielkości opisujące jednorodność zostały szerzej opisane w Rozdziale 4.3.
- 3) Kontrola wizualna – wykonywana manualnie przez operatorów Działu Inspekcji Końcowej. Przeprowadza się ją pod kątem wykrycia defektów, na stanowiskach zapewniających odpowiednie natężenie światła, wyposażonych w zespół rolek (ułatwiający obrót opony w celu jej oględzin) i rozwieraki (umożliwiają rozchylenie boków opony do oceny jej wnętrza).

W zależności od indywidualnych wymagań jakościowych klienta i specyfiki danego typu opony, konieczne do przeprowadzenia mogą być dodatkowe badania, tj. szerografia – nieniszcząca metoda umożliwiająca detekcję pęcherzy powietrza uwięzionych w strukturze opony. Technika ta znajduje zastosowanie głównie w segmencie opon przeznaczonych do zastosowań ekstremalnych, np. w samochodach sportowych.

Opony, które uzyskają pozytywną ocenę na etapie inspekcji końcowej, zostają automatycznie przetransportowane za pomocą przenośnika rolkowego do Magazynu Opon, skąd są kierowane do dalszej dystrybucji.



Rysunek 3.9. Maszyna TUO do pomiaru jednorodności opon (materiały własne przedsiębiorstwa)

Jak wspomniano na początku bieżącego podrozdziału, wszystkie opony opuszczające zakład produkcyjny podlegają obowiązkowej inspekcji końcowej. Nie stanowi ona jednak kompletnej kontroli jakości, której podlega opona jako produkt mający spełniać wymagania klienta, a także restrykcje związane z regulacjami danego rynku zbytu (homologacjami). Zakres nadzoru jakościowego (tj. liczba badanych próbek, rodzaje testów oraz częstotliwość ich przeprowadzania) ustalany jest indywidualnie dla każdego rozmiaru opony w zależności od jej konstrukcji, homologacji oraz specyfikacji klienta. Specyfika tej części kontroli jakości opon została szerzej opisana w kolejnym rozdziale.

4. Kontrola jakości opon na tle wymagań klienta

Opona jako element odpowiadający bezpośrednio za bezpieczeństwo, komfort jazdy oraz efektywność paliwową pojazdów, podlega szczególnie precyzyjnej ocenie jakościowej. Proces kontroli jakości w produkcji ogumienia nie ogranicza się jedynie do spełnienia wymogów norm technicznych i regulacyjnych (np. homologacyjnych). Musi również uwzględniać specyficzne, często zindywidualizowane wymagania klientów – zarówno tych instytucjonalnych (producenci samochodów osobowych), jak i detalicznych. Obejmuje to między innymi takie właściwości jak wytrzymałość, łatwość montażu, poziom hałasu, opory toczenia, zgodność z normami ekologicznymi, a nawet estetykę produktu. Celem niniejszego rozdziału jest przedstawianie procesu kontroli jakości opon w kontekście oczekiwań klienta, ze szczególnym uwzględnieniem metod oceny ich parametrów technicznych stosowanych w przemyśle oponiarskim.


4.1 Podział defektów opon oraz sposoby ich eliminacji

Efektywne zarządzanie odpadami w przedsiębiorstwie zajmującym się produkcją opon wymaga uprzedniego zidentyfikowania i sklasyfikowania przyczyn generowania odpadów (Weyssenhoff i in., 2019). Jednym ze sposobów takiej klasyfikacji jest podział na defekty wizualne (*ang. molding defects*¹) oraz defekty wynikające z przekroczenia dopuszczalnych limitów własności opisujących jednorodność opon. Do kategorii defektów wizualnych zalicza się m.in.:

- 1) Obecność ciał obcych, tj.: luźny drut opasania, odstający drut drutowki, papier, metal, nici, drewno, spieki gumowe.
- 2) Wtrącenia powietrza w przekroju poprzecznym opony (Rysunek 4.1. i 4.3.) zlokalizowane w obszarach, tj.: pod wykładziną wewnętrzną – w obrębie barku, bieżnika, boku, drutowki, a także pomiędzy warstwami komponentów budujących oponę oraz na ich złączach.
- 3) Ubytki powierzchniowe, obejmujące m.in. bieżnik, bark, bok (Rysunek 4.4.), drutowkę, a także lokalne i obwodowe ubytki wykładziny wewnętrznej (Rysunek 4.3.).
- 4) Defekty związane z kordami tekstylnymi, np.: widoczny chafer/osnowa na podstawie drutowki, zmarszczka osnowy, wypłyniecie osnowy (Rysunek 4.4.), przemieszczenie nitek osnowy (Rysunek 4.2.), widoczna nitka osnowy.

¹ Określenie najczęściej stosowane w języku branżowym.

- 5) Nadlewki powstające najczęściej na nosku drutowki, łączeniach segmentów bieźnika oraz na linii podziału formy MPL (*ang. mold partition line*) (Rysunek 4.2.).
- 6) Pęknięcia, np. wkładki RFT lub podstawy drutowki.




Rysunek 4.1. Powietrze pod wykładziną wewnętrzną w obszarze barku opony (opracowanie własne)



Rysunek 4.2. Nadlewka na linii podziału formy (po lewej) oraz przemieszczenie nitek osnowy (po prawej) (opracowanie własne)

- 7) Zniekształcenia, np.: deformacje drutowki, bieżnika, całej opony oraz zapadnięcie boków.
- 8) Separacje warstw, np. oddzielenie wykładziny wewnętrznej od wkładki RFT.
- 9) Pęcherze powietrza na powierzchni zewnętrznej opony – w szczególności w obszarze drutowki i boku.
- 10) Podwinięcia, np. chafera.
- 11) Defekty wynikające z niewłaściwej jakości złączy: rozejścia (przerwa w ciągłości danego materiału wynikające ze zbyt małej zakładki złącza), zbyt duże złącza, psie ucho.
- 12) Uszkodzenia mechaniczne wynikające z przemieszczania podczas i pomiędzy procesami produkcyjnymi, np.: przez przenośniki (wulkanizacja), trymowarkę (zacięcia), TUO (zgniecenie opony), przytarcia (transportery rolkowe).
- 13) Defekty związane z niedoskonałościami formy lub membrany wulkanizacyjnej, np.: zabrudzenia (negatyw ciała obcego odbity w oponie zwulkanizowanej), zagłębiony/wystający odpowietrznik, brak wkładki (element oddający odpowiednią część stampingu formy), błąd cyklu wulkanizacyjnego (niezwulkanizowana opona), uszkodzona/pęknięta/podwinięta/ zużyta membrana.



Rysunek 4.3. Powietrze pod wykładziną wewnętrzną w połączeniu z jej obwodowym ubytkiem w obszarze barku opony (opracowanie własne)



Rysunek 4.4. Ubytek boku (po lewej) oraz wypłynięcie osnowy (po prawej) (opracowanie własne)

Metodami i narzędziami służącymi do identyfikacji wspomnianych defektów są kontrola wizualna, X-Ray i szerograf. Myśląc o molding defects, możliwe jest również zaproponowanie podziału według etapu procesu produkcyjnego w którym dany defekt powstaje (czyli tzw. „podziału procesowego”), tj. wady spowodowane nieprawidłowościami w procesie wytłaczania, konfekcji, wulkanizacji, etc.

Natomiast do defektów związanych z przekroczeniem limitów własności opisujących jednorodność opon zalicza się:

- 1) Wada RFV.
- 2) Wada RFV1H – RFVxH.
- 3) Wada LFV.
- 4) Wada CON.
- 5) Wada LRO.
- 6) Wada LRP – wybrzuszenie / wgłębienie.
- 7) Wada RRO.
- 8) Wada wyważenia dynamicznego.
- 9) Wada wyważenia statycznego.

Wymienione wyżej defekty wykrywane są na podstawie pomiaru przeprowadzanego przez maszyny Rim Flow i TUO. Odnalezienie źródła tych wad wymaga najczęściej wieloetapowej analizy danych z rejestru masowej produkcji. Ich detekcja jest ważna, ponieważ bicie promieniowe wywołane niejednorodnością masy opony może powodować powstawanie wyczuwalnych drgań, często błędnie interpretowanych jako awaria części zawieszenia

lub układu kierowniczego samochodów osobowych (Bęczkowska i in., 2018). Znaczenie jednorodności opon zostało szerzej opisane w Rozdziale 4.3.

Złożoność procesu produkcji opon stanowi istotne wyzwanie technologiczne, będące impulsem do ciągłego rozwoju metod wspierających identyfikację oraz eliminację wymienionych wyżej defektów. W literaturze przedmiotu można znaleźć liczne sposoby, koncentrujące się na wykrywaniu oraz minimalizacji wad generowanych w toku wytwarzania opon. Jednym z podstawowych podejść wykorzystywanych w tym obszarze jest zastosowanie Metody Elementów Skończonych (MES). Jak wykazano w pracy (Jeong i in., 2007), metoda ta może być przydatna w analizie wpływu zmian sztywności oraz niedoskonałości wymiarowych opony radialnej na jej jednorodność. Umożliwia ona uwzględnienie rzeczywistych niedoskonałości w trójwymiarowym modelu numerycznym, co z kolei pozwala na przewidywanie parametrów jednorodności na podstawie nieregularności w rozkładzie masy opony. Wnioski te zostały potwierdzone również przez autorów (Oertel i Wei, 2007; Wei i Oertel, 2012), którzy dodatkowo wskazali, iż do estymacji siły stycznej możliwe jest wykorzystanie uproszczonych modeli obliczeniowych oraz technik analitycznych. Kolejnym podejściem jest wdrażanie narzędzi jakościowych w strukturach przedsiębiorstw przemysłu oponiarskiego. Przykładowo, dzięki implementacji metody rozwijania funkcji jakości QFD (*ang. Quality Function Deployment*) autorzy pracy (Hadi i in., 2017) byli w stanie precyzyjnie zidentyfikować rzeczywiste potrzeby klienta, co bezpośrednio przełożyło się na poprawę procesu produkcyjnego już na etapie projektowania wyrobu.

Równolegle prowadzone są działania ukierunkowane na rozwój metod pomiarowych w celu uzyskania wyższej precyzji wyników, stanowiących podstawę budowy i weryfikacji modeli matematycznych. Przykład stanowi publikacja (Li, 2021), w której przedstawiono poprawę dokładności pomiaru balansu dynamicznego opony poprzez zastosowanie metody najmniejszych kwadratów. Z kolei w pracy (Zhu i Ai, 2018) opracowano algorytm automatycznego wykrywania defektów na podstawie obrazów rentgenowskich, umożliwiającą zwiększenie dokładności kontroli jakości i jednocześnie ograniczenie obciążenia operatorów. Do nowatorskich rozwiązań zalicza się również technikę wykorzystującą otwartą sondę falowodową, zaprezentowaną przez autorów (Sutthaweekul i in., 2016), która w przyszłości może znaleźć zastosowanie w wykrywaniu defektów wewnętrznych opony. Postęp obserwowany jest również w zakresie automatyzacji kontroli wizualnej powierzchni zewnętrznej opony. Przykładowo, w pracy (Funahashi i in., 2015) opisano zastosowanie pasm świetlnych, które umożliwiają identyfikację defektów o niewielkich rozmiarach dzięki wyeksponowaniu ich na powierzchni badanego elementu.

W celu lepszego zrozumienia zjawisk fizycznych zachodzących w strukturze opony opracowywane są również nowe metody pomiarowe. Jednym z kierunków rozwoju w tym zakresie jest wprowadzanie obowiązkowego pomiaru jednorodności przy wysokich prędkościach HSU (*ang. High-Speed Uniformity*). W porównaniu do dotychczasowych metod pomiaru jednorodności przy niskich prędkościach LSU (*ang. Low-Speed Uniformity*), pomiar HSU pozwala na detekcję fluktuacji momentów obrotowych opony, co umożliwia bardziej wiarygodne odwzorowanie jej zachowania w warunkach rzeczywistych (Du i in., 2020).

Coraz większe znaczenie w analizie danych produkcyjnych zyskują również techniki sztucznej inteligencji, które pozwalają na identyfikację wzorców i anomalii w dużych zbiorach danych. Przykładem takiego podejścia jest metoda opisana przez autorów (Strano i in., 2021), w której zastosowano modele uczenia maszynowego do prognozowania sił bocznych generowanych przez oponę w trakcie ruchu. W pracy (Barbosa i in., 2022) porównano różne modele predykcyjne, wykazując, że proces Gaussowski charakteryzuje się najwyższą dokładnością, minimalizując błędy względem danych pozyskanych z akcelerometru. Zbliżoną problematykę poruszono w badaniu (Xu i in., 2022), gdzie dane z przyspieszeniomierza stanowiły podstawę do nauczania sieci neuronowej, która następnie została wykorzystana do predykcji sił generowanych przez oponę w czasie rzeczywistym.

4.2 Specyfikacja wymagań klienta

Cykl życia opony rozpoczyna się na etapie zdefiniowania wymagań klienta, które stanowią fundamentalny punkt wyjścia dla całego procesu rozwoju produktu. Współczesne podejście do projektowania opon opiera się na zasadzie „*design to customer needs*”, zgodnie z którą oczekiwania odbiorcy końcowego – w zakresie właściwości technicznych i funkcjonalnych – determinują kluczowe założenia konstrukcyjne. W odpowiedzi na specyficzne potrzeby klienta często konieczne jest opracowanie nowego rozmiaru opony, który nie występuje w dotychczasowym portfolio producenta. Specyfikacja klienta (producenta samochodów osobowych) reguluje najczęściej poniższe wymagania dotyczące danego rozmiaru opon:

- 1) Rozmiar (szerokość / profil / cal).
- 2) Typ opony (symetryczna / asymetryczna, kierunkowa / niekierunkowa).
- 3) Model auta, do którego jest dedykowana.
- 4) Rynek zbytu.
- 5) Limit oporu elektrycznego.
- 6) Twardość bieżnika.

- 7) Limity własności opisujących jednorodność oraz warunki pomiarowe narzucone do ich wyznaczania (szerokość i profil felgi pomiarowej / obciążenie / ciśnienie).
- 8) Limity własności opisujących jednorodność wysokich prędkości (HSU) oraz warunki pomiarowe narzucone do ich wyznaczania (nie występuje dla każdego klienta).
- 9) Masa opony.
- 10) Limity siły i ciśnienia osadzenia stopki.
- 11) Wymiary fizyczne.
- 12) Wymagane testy wysokich i niskich prędkości wraz z limitami.
- 13) Homologacje oraz dodatkowe testy związane z otrzymaniem certyfikacji.
- 14) Oznaczenia mające znaleźć się na boku opony (tzw. *stamping*) - Rysunek 4.5.
- 15) Obecność dodatkowych oznaczeń, np. kod QR, RFID (Gao i in., 2010).
- 16) Etykieta opony, czyli wymagane klasy oporów toczenia, przyczepności na mokrej nawierzchni oraz emisji hałasu.
- 17) Linie kolorowe.
- 18) Dopuszczalność napraw po procesie produkcji.
- 19) Termin dostarczenia do klienta.




Rysunek 4.5. Oznaczenia (*stamping*) na boku opony (opracowanie własne)

Wdrożenie nowego rozmiaru opony stanowi więc wynik świadomej, wieloetapowej pracy nad doбором komponentów składowych opony o odpowiedniej geometrii (tzw. design opony), kordów tekstylnych i stalowych będących w stanie sprostać założonym kryteriom, a także składu mieszanek gumowych w celu uzyskania produktu w pełni zgodnego z oczekiwaniami klienta oraz normami branżowymi.

Wymagania rynku kreują coraz większą świadomość klienta o produkcie który nabywa, czego przykładem jest zwiększenie ilości informacji na etykiecie UE od 01.05.2021 (Rysunek 4.6.). Etykieta opony zawiera 3 podstawowe parametry wyznaczane zgodnie z rozporządzeniem Regulaminu nr 117 Europejskiej Komisji Gospodarczej ONZ (UNECE, 2025) oraz następującymi normami ISO:

- 1) Opór toczenia (efektywność paliwowa) – przypisywana jest mu klasa od A (najniższy opór, największa efektywność paliwowa) do E (najwyższy opór). Norma (ISO, 2018) określa sposób pomiaru oporu toczenia w warunkach laboratoryjnych. Wyznaczanie współczynnika oporu toczenia zostało szerzej opisane w Rozdziale 4.4.5.
- 2) Hamowanie na mokrej nawierzchni (przyczepność na mokro) - pomiar odbywa się w warunkach kontrolowanych, zgodnie z procedurą opisaną w (ISO, 2024) jest oceniane w klasach od A (najkrótsza droga hamowania) do E.
- 3) Emisja hałasu zewnętrznego – zgodnie z (ISO, 2003) mierzy się hałas emitowany przez oponę podczas przejazdu bez przyspieszania. Wynik podawany jest w decybelach [dB] i oznaczany dodatkowo ikoną z 1, 2 lub 3 falami (im mniej fal, tym cichsza opona).



Rysunek 4.6. Informacje zawarte na etykiecie opony (Janiszewski, 2025)

System etykietowania promuje produkcję i wybór opon o niższych oporach toczenia, co przekłada się na zmniejszenie zużycia paliwa i tym samym redukcję emisji CO₂. Opony o niskim poziomie hałasu przyczyniają się również do ograniczenia zanieczyszczenia hałasem, co ma istotne znaczenie w kontekście ochrony zdrowia. Normatywne podejście do oceny parametrów opon tworzy przejrzyste warunki konkurencji na rynku, sprzyjające rozwojowi zrównoważonych produktów. Standaryzacja pomiarów umożliwia obiektywne porównanie jakości między producentami, co podnosi jakość oferowanych wyrobów. Deklaracje klas własności opony zawarte na etykiecie (w szczególności emisja hałasu) są ściśle związane z jej jednorodnością.

4.3 Jednorodność opon

Jednorodność (Polski Komitet Normalizacyjny, 2002) to stan, w którym każda właściwość opony mierzona zarówno w warunkach statycznych, jak i dynamicznych, jest niezmienna wzdłuż jej obwodu biorąc pod uwagę fazę i wartość bezwzględną. Jednorodność jest związana z symetrycznym rozmieszczeniem masy względem osi, z jednorodnością geometryczną i siłami wywołanymi ruchem masy. Brak jednorodności opony obracającej się wokół osi powoduje wahania sił, które mogą się zmieniać w zależności od prędkości i odnoszą się do określonej osi.


Tabela 4.1. Zależności pomiędzy jednorodnością opony a zjawiskami wibracyjnymi pojazdów
(opracowanie własne na podstawie Nakajima, 2019)

Jednorodność		Typ drgań	Zjawiska w pojeździe
Bicie promieniowe Niewyważenie	RFV Unbalance	Drgania przy dużej prędkości 80–160 [km/h]	Pionowe drgania nadwozia, fotela i kierownicy
Bicie boczne	LFV	Boczne drgania przy małej prędkości 30–50 [km/h]	Boczne drgania fotela
		Shimmy ² przy małej prędkości 20–60 [km/h]	Boczne drgania kierownicy
Stożkowatość	CON	-	Ściąganie pojazdu

² Efekt shimmy - oscylacyjne drganie kierownicy odczuwalne podczas jazdy, występujące zazwyczaj w określonym zakresie prędkości.

Jednorodność fizyczna jest jednym z aspektów jakościowych świadczących o jednorodnej strukturze opony, która jest również miarą jej zdolności do płynnej pracy bez wibracji (Rodgers i Waddell, 2005). Składa się z pakietu wielkości fizycznych mierzonych dla każdej opony przed opuszczeniem fabryki. Istnieją zjawiska promieniowe: zmienność siły promieniowej RFV (*ang. radial force variation*), wyważenie statyczne (*ang. static balance*), wyważenie dynamiczne (*ang. dynamic balance*), bicie promieniowe RRO (*ang. radial runout*) oraz zjawiska boczne: zmienność siły bocznej LFV (*ang. lateral force variation*), bicie boczne LRO (*ang. lateral runout*), stożkowatość CON (*ang. conicity*) i tzw. siła boczna strukturalna (*ang. ply steer*). Opisują one m.in. równomierne rozłożenie masy na obwodzie opony (Koketsu, 2017), co bezpośrednio przekłada się na mechanizm jej zużycia (Hosseini Salari, 2023). Oprócz wpływu rzeźby bieżnika (Nakajima, 2019), są one również jednym z czynników wpływających na emisję hałasu opony podczas toczenia. Zależności pomiędzy jednorodnością opony a zjawiskami wibracyjnymi pojazdów przedstawiono w Tabeli 5.1. Zapewnienie jednorodności opon na poziomie zużycia przyczynia się zatem do zwiększenia ich trwałości i przewidywalnego zachowania w ruchu drogowym przez cały okres eksploatacji.

W teorii wibracji, wymienione wcześniej zjawiska są ze sobą powiązane, dlatego każda decyzja projektowa wpływająca na jeden z czynników będzie oddziaływać również na pozostałe - pozytywnie lub negatywnie. W rezultacie powstaje złożony układ sił działających na toczącą się oponę zamontowaną w pojeździe (Rysunek 4.7.). Właściwości mechaniczne opony opisują jej zachowanie pod wpływem obciążenia, momentu obrotowego i działania układu kierowniczego, czego efektem jest powstawanie sił zewnętrznych i odkształceń (Rodgers i Waddell, 2005). Układ osi opony odnosi się do środka styku opony z nawierzchnią drogi, jak pokazano na Rysunku 4.7. Oś X to linia przecięcia płaszczyzny koła z płaszczyzną drogi, skierowana w stronę jazdy (kierunek dodatni do przodu). Oś Z jest prostopadła do płaszczyzny drogi i skierowana w dół (kierunek dodatni). Oznacza to, że siła normalna wywierana przez oponę ma zwrot dodatni w dół, natomiast pionowa reakcja obciążenia – czyli siła, z jaką droga działa na oponę – jest uznawana za ujemną. Oś Y leży w płaszczyźnie drogi i jest skierowana w taki sposób, aby układ tworzył układ prawoskrętny i ortogonalny. Takie przedstawienie układu osi opony odpowiada układowi osi pojazdu, gdy opona znajduje się na prawym przednim kole samochodu.




Rysunek 4.7. Siły i momenty działające na oponę w centralnym punkcie jej styku z nawierzchnią (Rodgers i Waddell, 2005)

W przypadku przedstawionym na Rysunku 4.7. pojazd skręca w lewo, a więc występuje dodatni moment samokierujący (M_z) oraz ujemna siła boczna. Siły działające na oponę można zatem rozłożyć na trzy podstawowe wektory:

- 1) Siły pionowe (normalne) – wpływają na komfort jazdy.
- 2) Siły boczne – mają wpływ na kontrolę nad pojazdem.
- 3) Siły wzdłużne (do przodu) – wpływają na osiągi, takie jak opory toczenia.


Jednym z powodów, dla których przeprowadza się obowiązkowy pomiar jednorodności opon jest zapobiegnięcie wypuszczenia na rynek produktu, w którym mogłoby dojść do wystąpienia mechanizmu nieregularnego zużycia w trakcie eksploatacji (Rysunek 4.8.). Każda z sił występujących podczas ruchu opony odpowiada za swoisty sposób jej zużycia. Niektóre z przedstawionych niżej mechanizmów zostaną omówione w niniejszym podrozdziale.




Rysunek 4.8. Przykładowe rodzaje nieregularnego zużycia opon (opracowanie własne na podstawie Nakajima, 2019)

4.3.1 Zmienność siły promieniowej i jej wyższe harmoniczne

Wartość całkowita zmienności siły promieniowej RFV to różnica między wartością maksymalną i minimalną mierzonego sygnału w obrębie pasma określonej szerokości, występująca podczas jednego obrotu. Należy ją rozumieć jako wartość siły w kierunku promieniowym (w osi Z) opony obciążonej (Rysunek 4.9.), powtarzającą się dla każdego obrotu, przy zachowaniu stałego promienia pod obciążeniem i stałej prędkości, wyrażona w niutonach [N] (Polski Komitet Normalizacyjny, 2002). Jej obecność jest spowodowana występowaniem złącz komponentów opony (miejsca o zwiększonej lokalnej masie na obwodzie w stosunku do sąsiadujących z nimi miejscami) prowadzących do wzrostu siły promieniowej. Z kolei lżejsze miejsca w oponie, przykładowo spowodowane rozejściem kordu osnowy, powodują lokalny spadek siły promieniowej na obwodzie opony (Rodgers i Waddell, 2005). Wariacje siły i momentu powtarzają się przy każdym obrocie opony, a zatem są okresowe względem fizycznego położenia na oponie. Rysunek 4.10. ilustruje, jak może wyglądać zmienność siły promieniowej przy niskiej prędkości. Górna krzywa to skumulowany, czyli całkowity sygnał zmienności siły promieniowej. Przeprowadzając analizę Fouriera, możliwe jest rozłożenie sygnału skumulowanego i uwidocznienie poszczególnych harmoniczných, czyli rzędów drgań. Na Rysunku 4.10. przedstawiono pierwsze sześć harmoniczných. Harmoniczne przyciągają większą uwagę niż skumulowana zmienność siły, ponieważ zazwyczaj łatwiej jest powiązać wewnętrzną anomalię opony z jedną lub kilkoma harmonicznymi niż z całkowitym przebiegiem falowym, co pozwala na skuteczniejsze zidentyfikowanie i usunięcie problemu (Gent i Walter, 2006).




Rysunek 4.9. Układ osi odniesienia sił podczas pomiaru jednorodności opon m.in. na maszynie TUO; gdzie: 1 – bęben pomiarowy, 2 – opona (Polski Komitet Normalizacyjny, 2002)



Rysunek 4.10. Pierwsze sześć harmoniczných oraz ich wektor sumacyjny (opracowanie własne na podstawie Rodgers i Waddell, 2005)

Zgodnie z tą wiedzą, pierwsza harmoniczna zmienności siły promieniowej RFV1H to amplituda wartości całkowitych składowej częstotliwości podstawowej transformaty (funkcji) Fouriera przedstawiającej wahania (Polski Komitet Normalizacyjny, 2002). Natomiast wyższe harmoniczne to amplituda wartości całkowitych drugiej (lub wyższego

rzędu) składowej częstotliwości transformaty Fouriera przedstawiającej te wahania (Polski Komitet Normalizacyjny, 2002). Na tej podstawie przeprowadzana jest analiza fali RFV, która pomaga w dotarciu do przyczyny zbyt dużej wartości tej zmiennej opisującej jednorodność. W tym celu zestawia się fale reprezentatywnych opon problematycznego rozmiaru opon na jednym wykresie (zmiana siły promieniowej w funkcji obrotu opony na bębnie pomiarowym), a następnie wyznacza się średnią falę badanej populacji, co zostało zaprezentowane na Rysunku 4.11. Oceniana jest również powtarzalność fali RFV, która pozwala na stwierdzenie, czy istnieją dodatkowe czynniki wpływające na jej zakłócenie.



Rysunek 4.11. Analiza fali RFV (opracowanie własne)

Dzięki ustalonemu dla danego rozmiaru opony rozkładowi złącz wiadomo, w których miejscach na obwodzie opony dochodzi do największych wahań siły (pozycje złącz materiałowych zostały naniesione na dolnym wykresie Rysunku 4.11. na podstawie rozkładu złącz zastosowanego podczas procesu konfekcji). Widoczne są zatem miejsca występowania najwyższej i najniższej wartości siły. Pierwszym działaniem dla osiągnięcia możliwego „spłaszczenia” fali jest nałożenie tych miejsc na siebie, czyli zmiana rozkładu złącz (Rysunek

4.12.). Następnie dochodzi do powtórnej analizy i weryfikacji, czy przeprowadzone działania przyniosły zamierzony skutek, czy też należy poszukiwać innych rozwiązań obniżających wartość RFV.



**Rysunek 4.12. Rozkład złącz poprawiony na podstawie przeprowadzonej analizy fali RFV
(opracowanie własne)**

Istnieje wiele potencjalnych przyczyn niejednorodności opony, jednakże istnieje również ogólna tendencja, że określone anomalie materiałowe lub konstrukcyjne mają większy wpływ na zmienność siły w kierunku promieniowym lub wzdłużnym. Anomalie wpływające na zmienność masy wokół obwodu opony mają istotne znaczenie dla zmienności siły promieniowej, natomiast anomalie wpływające na sztywność lub bicie mają większy wpływ na zmienność siły wzdłużnej (Pacejka, 2012). Tabela 4.2. zawiera porównanie różnych potencjalnych źródeł zmienności sił.

Tabela 4.2. Potencjalne źródła zmienności sił powodujące niejednorodność opon (opracowanie własne na podstawie Gent i Walter, 2006)

Źródło	Wpływ na zmienność siły promieniowej RFV	Wpływ na zmienność siły wzdłużnej
Zbyt ciężkie lub zbyt lekkie złącze	istotny	niewielki
Rozrzedzenie lub spiętrzenie kordu	istotny	niewielki
Zmienność grubości bieżnika	istotny	niewielki
Niesymetryczne osadzenie drutówek	niewielki	istotny
Niedoskonałości bębna karkasu i/lub B&T	niewielki	istotny
Niedoskonałości formy wulkanizacyjnej	niewielki	istotny
Bicie karkasu	niewielki	istotny

Przez wiele lat opony były szlifowane na fabrycznych maszynach do pomiaru jednorodności w celu zmniejszenia zmienności siły promieniowej (Nedley i Gearig, 1970). Proces ten jest zazwyczaj najskuteczniejszy w przypadku pierwszej harmonicznej siły

promieniowej, która ma kluczowe znaczenie dla poprawy komfortu jazdy. Szlifowanie polega na usunięciu niewielkiej ilości gumy z barku opony lub z całej powierzchni bieżnika w miejscu odpowiadającym punktowi o najwyższej wartości RFV1H. Szlifowanie nie jest jednak akceptowane przez wszystkich producentów samochodów.

„Dopasowywanie poprzez znakowanie” to kolejna technika stosowana w celu zminimalizowania RFV1H. Metoda ta jest zazwyczaj stosowana na końcu linii montażowej pojazdu lub w firmach outsourcingowych, gdzie opony są zakładane na felgi. W tym procesie opona i felga są ustawiane w taki sposób, aby punkt maksymalny RFV1H felgi (najczęściej to miejsce montowania wentylu) pokrywał się z punktem minimalnym pierwszej harmonicznej opony. Z tego powodu wymaganiem wielu producentów samochodów jest oznaczanie na boku opony jej najlżejszego punktu. Dzięki temu minimalizuje się całkowitą pierwszą harmoniczną zmienności siły promieniowej dla zespołu opona + felga tworzącego koło pojazdu.

Jednorodność opony jest najważniejszym źródłem wzbudzenia drgań powodujących podskakiwanie / boksowanie koła (*ang. wheel hop*), chociaż w pewnych warunkach mogą je również wywołać nierówności drogi. Głównym czynnikiem jest pierwsza harmoniczna zmienności siły promieniowej, a krytyczna prędkość jazdy to 80 km/h i więcej. Gdy rezonans boksowania zostaje wzbudzony, pojawia się zakłócenie komfortu jazdy określane zwykle jako drgania. Problem ten można kontrolować na dwa sposoby (Gent i Walter, 2006):

- 1) RFV1H powinna być niska w całym zakresie prędkości roboczych. Wymagany poziom siły (limit) zależy od wrażliwości konkretnego pojazdu. Dlatego też, będąc świadomym autorskich technologii zaimplementowanych na etapie projektowania zawieszenia pojazdu, każdy producent aut narzuca własne limity pierwszej harmonicznej siły promieniowej.
- 2) Należy możliwie jak najbardziej przesunąć rezonans inicjacji boksowania ku wyższym częstotliwościom. Po pierwsze, należy upewnić się, że prędkość przy której boksowanie jest najsilniej wzbudzane, znajduje się powyżej normalnego zakresu prędkości jazdy. Po drugie, ciało ludzkie jest mniej wrażliwe na drgania o częstotliwości 20 [Hz], niż na te o częstotliwości 10 [Hz]. Dlatego podskakiwanie inicjowane przy wyższej częstotliwości jest mniej dokuczliwe dla kierowcy i pasażerów.

4.3.2 Zmienność siły bocznej


Generowanie siły bocznej przez układ kierowniczy auta jest konieczne, ponieważ stanowi to podstawę sterowania pojazdem. Jednak duże ruchy kierownicą są zazwyczaj stosowane tylko w niewielkim procencie czasu jazdy pojazdu, dlatego zmniejszenie oporów toczenia podczas

skręcania ma niski priorytet. Szczególnie istotne są odkształcenia bieżnika i opasań w obszarze kontaktu z nawierzchnią podczas skrętu, które nie tylko powodują dodatkowe naprężenia i odkształcenia, ale również przyczyniają się do powstawania dodatkowego ciepła na skutek zwiększonej histerezy (powrót opony po odkształceniu do pierwotnego kształtu) i ścierania bieżnika. Zmiennymi wpływającymi na skalę tego zjawiska są czas trwania i szybkość skrętu oraz kąt poślizgu (zwany również kątem znoszenia) podczas manewru. Siła boczna jest nieliniową funkcją kąta poślizgu i kąta pochylenia koła (Gent i Walter, 2006).

Zmienność siły bocznej LFV to wartość wahania siły w kierunku bocznym (w osi Y) opony obciążonej (Rysunek 4.9.), powtarzająca się dla każdego obrotu, przy zachowaniu stałego promienia pod obciążeniem i stałej prędkości, wyrażona w niutonach [N] (Polski Komitet Normalizacyjny, 2002). Siła boczna F_y , to siła działająca ze strony drogi na oponę wzdłuż osi Y (Rysunek 4.7.), wymuszająca ruch pojazdu w lewo lub w prawo, w zależności od tego, czy koło jest skręcone i/lub pochylone w lewo bądź w prawo. Opona generuje siłę boczną w odpowiedzi na dwie główne zmienne kątowe α i γ (Rysunek 4.7.). Jeśli tor ruchu opony ma bardzo dużą krzywiznę, czyli bardzo mały promień skrętu – sama krzywizna toru wyraźnie wpływa na generowanie siły bocznej oraz momentu wyrównawczego.

W odniesieniu do punktu na wykresie, w którym $F_y = 0$ jak pokazano na Rysunku 4.13., siła boczna zazwyczaj nie jest zerowa dla kąta poślizgu $\alpha = 0$. Jak można się spodziewać, siła boczna przy zerowych kątach pochylenia i znoszenia nie jest zerowa, ze względu na współistniejące siły ściągające. Jedną z tych sił – plysteer – jest związana z samosterowaniem indukowanym strukturalnie (tutaj w rozumieniu: konstrukcyjnie), a druga (stożkowatość) z samopozycjonowaniem się opony na skutek strukturalnych właściwości. Jest to istotna cecha zachowania opony, nawet w pozycji jej idealnego wycentrowania (rozwiniecie tych zjawisk zostanie opisane w Rozdziale 4.3.5). Ujemna siła boczna jest związana z dodatnim kątem poślizgu, a dodatnia siła boczna – z ujemnym kątem poślizgu. W normalnym zakresie jazdy nachylenie krzywej siły bocznej względem kąta poślizgu jest ujemne. Wartość bezwzględna nachylenia krzywej siły bocznej przy zerowym kącie poślizgu jest powszechnie nazywana sztywnością boczną (Luty, 2009). Jest to bardzo ważny parametr określający zachowanie pojazdów w zakresie liniowego zachowania F_y , czyli w obszarze, w którym odbywa się większość czasu jazdy. Sztywność boczna zależy od obciążenia (siły normalnej). Zazwyczaj rośnie do pewnej części nominalnego obciążenia opony, a następnie stopniowo maleje wraz ze wzrostem obciążenia (Gent i Walter, 2006). Miejsce, w którym sztywność boczna osiąga maksimum zależy od konstrukcji opony. Dla dobrego prowadzenia pojazdu pożądane jest, aby maksimum występowało na poziomie

nominalnego obciążenia opony lub powyżej niego. Powoduje to dodatnią wartość czułości na obciążenie, którą definiuje się jako nachylenie krzywej siły bocznej pomiędzy 80% a 100% nominalnego obciążenia opony. Wzrost siły bocznej wraz z kątem poślizgu jest złożoną nieliniową funkcją. Wartość F_y przy określonej wartości kąta poślizgu osiąga szczyt, a następnie spada, podobnie jak w przypadku opony poddanej hamowaniu wzdłużnemu. Wraz ze wzrostem kąta poślizgu coraz większa część dostępnego obszaru styku bierze udział w poślizgu, przez co w pewnej wartości kąta poślizgu generowana jest maksymalna siła boczna. Po przekroczeniu tej granicznej wartości kąta, dalszy wzrost poślizgu powoduje systematyczny spadek siły bocznej (dochodzi do poślizgu pojazdu) (Gent i Walter, 2006).



Rysunek 4.13. Zależność siły bocznej od kąta znoszenia przy stałej sile normalnej (Gent i Walter, 2006)

W praktyce, początkowy zakres siły bocznej, aż do kąta poślizgu związanego ze szczytem siły F_y to zakres, w którym kierowca może utrzymać kontrolę nad pojazdem. Prawdopodobieństwo utraty kontroli podczas pokonywania zakrętu rośnie, gdy kąt poślizgu zbliża się do wartości odpowiadającej maksymalnej sile bocznej dla normalnego obciążenia F_z (Rysunek 4.7). Ogólnie rzecz biorąc, zmniejszenie profilu opony powoduje, że dane dotyczące siły bocznej oraz innych sił i momentów wykazują większe początkowe nachylenia oraz gwałtowniejszą zmianę zachowania od tych początkowych nachyleń, do zakresów przy dużych kątach poślizgu. Szerokość strefy przejściowej pomiędzy dobrze kontrolowanym zachowaniem a możliwą utratą kontroli jest mniejsza pod względem kąta poślizgu dla opon o niższym profilu. Oznacza to, że opony niskoprofilowe lepiej poradzą sobie w ostrzejszym

zakręcie, jednak zerwanie przyczepności może nastąpić w nagły sposób, co daje mniejszy czas reakcji kierowcy na skontrolowanie manewru.

Podobnie jak boczne niewspółosiowości, zmienności w bocznej sztywności również prowadzą do niepożądanych wahań siły bocznej (LFV) w centrum koła oraz do bocznych drgań kabiny pasażerskiej (Tabela 4.1.). Częstotliwości wzbudzeń, które są wywołane brakiem jednorodności, są wielokrotnością prędkości obrotowej koła, tzn. wielkość wahań zależy bezpośrednio od prędkości pojazdu. Drgania te powodują dodatkowo zakłócenie mechanizmu przewidywalnego zużycia opony. Zużycie schodkowe (*ang. step-down wear*) oraz zużycie typu "rzeka" (*ang. river wear*) przedstawione na Rysunku 4.8. to rodzaje nieregularnego zużycia, które zazwyczaj występują w oponach toczących się stale po płaskiej nawierzchni, tj. autostrada. Rysunek 4.14. przedstawia genezę powstawania zużycia schodkowego, która przebiega w czterech etapach (Nakajima, 2019):


- 1) Ślad nieregularnego zużycia zaczyna się tworzyć w bieżniku opony pod wpływem siły bocznej. Przekrój poprzeczny zużytych żeber ma zaokrąglone krawędzie, a na powierzchni bieżnika pojawia się obwodowe przetarcie. Ponieważ kierunek siły zewnętrznej jest prostopadły do kierunku tego wzoru ścierania, oznacza to, że inicjacja tego zużycia wynika głównie na skutek działania siły bocznej.
- 2) Powstaje nieregularne zużycie. Wytarty ślad zaczyna być wyraźnie widoczny w kierunku poprzecznym (bocznym), a zużycie nasila się poprzez dodatkowe działanie sił wzdłużnych, w szczególności podczas hamowania.
- 3) Degradacja postępuje w kierunku środka żebra bieżnika pod wpływem sił wzdłużnych. Na tym etapie zużycie postępuje w przyspieszonym tempie. Ścieranie przebiega również poprzecznie, jednak w tym momencie propagacja zniszczenia wynika głównie z sił wzdłużnych. Stosunek powierzchni bieżnika między obszarem normalnego zużycia a obszarem zużycia nieregularnego staje się większy, natomiast nachylenie startej powierzchni w kierunku boku opony robi się bardziej strome. Wygląd zużytego bieżnika pogarsza się na tyle, że może prowadzić do reklamacji użytkownika. W obszarze normalnego zużycia ścieranie nie jest tak wyraźne, jednak siły zewnętrzne zaczynają działać na ten obszar bardziej intensywnie, ze względu na zmniejszanie się powierzchni styku opony z podłożem.
- 4) Nieregularne zużycie w końcu obejmuje całe zebro.



Rysunek 4.14. Mechanizm powstawania zużycia schodkowego wywołanego działaniem siły bocznej (opracowanie własne na podstawie Nakajima, 2019)


Rysunek 4.15. podsumowuje wpływ kątów pochylenia koła (*ang. camber*) oraz zbieżności / rozbieżności (*ang. toe-in / toe-out*) na nieregularne zużycie opon (Nakajima, 2019):

- 1) Przy rozbieżności – gdy przednia strona kół jest skierowana jest na zewnątrz względem osi jazdy – bardziej zużywa się wewnętrzna strona opony. Dzieje się tak, ponieważ siła boczna działa od wewnątrz opony.
- 2) Przy zbieżności – gdy przednia strona kół jest skierowana jest do środka – bardziej zużywa się zewnętrzna strona opony, ponieważ siła boczna działa od zewnątrz opony.



Rysunek 4.15. Możliwe niedoskonałości układu zawieszenia pojazdu potęgujące nieregularne zużycie opon wywołane działaniem siły bocznej (Nakajima, 2019)

Podczas eksploatacji pojazdów bardzo często dochodzi do utraty prawidłowej zbieżności zawieszenia. Z tego powodu niektórzy producenci samochodów uwzględniają kąt pochylenia opony w warunkach wymaganych przez nich testów bębnowych (wysokich prędkości). Kąt styku powierzchni bębna pomiarowego i opony θ wynosi zazwyczaj 5° , co zostało zobrazowane na Rysunku 4.16. Stwarza to trudniejszą sytuację dla osiągnięcia pozytywnego rezultatu, bo wymuszone jest dodatkowe działanie siły bocznej, a nie tylko normalnej i wzdłużnej, jak ma to miejsce w warunkach standardowego testu. Zużycie jest bardziej intensywne, przez co łatwiej może dojść do np. separacji warstw materiałów z których złożona jest opona.



Rysunek 4.16. Pozycja opony względem bębna pomiarowego dla testu bębnowego przeprowadzanego w standardowych warunkach (po lewej – kąt 0°) i dla testu typu *camber* (po prawej – kąt 5°)
(opracowanie własne)

4.3.3 Balans statyczny i dynamiczny

Dla ciała obracającego się wokół osi w stanie roboczym możliwe jest określenie rozkładu jego masy względem osi obrotu. Niezrównoważenie masy wirującej nazywa się niewyważeniem. Niewyważenia generują siły odśrodkowe, które z kolei wywołują siły reakcji w elementach zawieszenia auta. Złe wyważenie wynika z elementów o nieregularnych wymiarach (różnica w polu przekroju opony, związana np. z niestabilnością procesu wytłaczania). Na wyważenie mogą również wpływać nieregularne szerokości złączy komponentów opony oraz ich niewłaściwe nałożenie (Rodgers i Waddell, 2005). Czynniki te są powodem nieregularnego rozłożenia masy oraz sztywności na obwodzie opony.

Wyważenie koła ma istotny wpływ na jednorodność opony we wszystkich zakresach prędkości. Zjawisko niewyważenia jest często wykorzystywane do badania odporności

zmęczeniowej zawieszenia pojazdu. Niewyważenie rzędu 30 g w najwyższym punkcie pierwszej harmonicznej koła powoduje dodatkowe wzbudzenie siły wzdłużnej w oponie z powodu sił Coriolisa, które powstają w wyniku zmiennej prędkości ugięcia opony (czyli ciała ulegającego deformacji). Wzbudzenie siły pionowej przez RFV1H jest tłumione przez siły odśrodkowe przy danej prędkości, zapobiegając tym samym silniejszemu ugięciu w najbardziej miękkim punkcie opony. W takim przypadku druga harmoniczna RFV2H staje się dominująca (Leister, 2015).

Jeżeli opona obraca się z prędkością kątową ω , niewyważenie statyczne wywołuje siłę odśrodkową F_x prostopadłą do osi obrotu, określoną wzorem 4.1 (Polski Komitet Normalizacyjny, 2002):

$$F_x = m \times e \times \omega^2 \quad (4.1)$$

gdzie:

F_x – siła odśrodkowa;

m – masa ciała;

e – odległość środka masy od osi obrotu (mimośród);

ω – prędkość kątowa obrotu.

Opona pneumatyczna jest w rzeczywistości bryłą ulegającą deformacji, co oznacza, że rozkład masy, a więc mimośrodowość środka ciężkości, może zmieniać się z prędkością obrotową. Zatem w praktyce zaleca się przyjęcie, że e jest funkcją ω .

Jeżeli opona obraca się ze stałą prędkością kątową ω , niewyważenie dynamiczne wywołuje moment zginający M , prostopadły do osi obrotu, określony wzorem 4.2 (Polski Komitet Normalizacyjny, 2002):

$$M = (I_a - I_x) \times \sin \alpha \times \omega^2 \quad (4.2)$$

gdzie:

M – moment zginający względem osi;

I_a – główny moment bezwładności względem osi głównej obrotu;

I_x – główny moment bezwładności względem osi poprzecznej;

α – kąt między osią obrotu a osią główną bezwładności;

ω – prędkość kątowa obrotu.

Opona pneumatyczna jest w rzeczywistości bryłą ulegającą deformacji, co oznacza, że I_a i I_x , czyli względne niewyważenie dynamiczne, mogą zmieniać się wraz ze zmianą prędkości obrotowej. Zatem zaleca się przyjęcie, że I_a oraz I_x są funkcjami ω .

W celu minimalizacji zjawiska niewyważenia statycznego, przed każdym montażem na pojazd koła powinny zostać wyważone. Niewyważenie statyczne można wykryć na nieruchomym kole. Precyzyjna wyważarka to urządzenie pomiarowe, które pozwala określić wielkość oraz położenie katowe niewyważenia opony. Podczas wyważania koła należy stosować tylko jeden ciężarek wyważający na każde obrzeże felgi lub płaszczyznę wyważania. Po nałożeniu ciężarków całe koło powinno być ponownie przetestowane pod kątem pozostałego niewyważenia. Zarówno w testach statycznych, jak i dynamicznych, pozostałe niewyważenie nie powinno przekraczać 5[g]. Łączna masa wszystkich ciężarków nie powinna przekraczać 60[g], co odpowiada limitowi balansu statycznego zespołu opona + felga.

Kompensacja nierównomiernie rozłożonych mas pomiędzy felgą a oponą jest równie ważna jak dokładne wyważenie osiowe i promieniowe, jeśli chodzi o płynne toczenie się całego koła. W tym celu koła samochodów osobowych są zazwyczaj mierzone pod kątem balansu dynamicznego. Niewyważenie dynamiczne można wykryć tylko na obracającym się kole. Ze względu na istnienie wymiaru, którym jest szerokość felgi, pomiary wykonuje się w dwóch płaszczyznach (wewnętrzne i zewnętrzne osadzenie opony). Na podstawie tych pomiarów określa się niezbędną masę wyważającą, którą następnie umieszcza się w miejscu wskazanym przez maszynę do wyważania kół. Obciążniki wyważające mogą być przyklejane, zaciskane lub nabijane. Idealne miejsce na obciążniki wyważające na kołach wyważanych dynamicznie to maksymalna odległość od środka felgi, na jak największej średnicy (zgodnie z przedstawionymi powyżej wzorami). W większości pojazdów występuje błąd wyważenia wynoszący około 5 g na każdą płaszczyznę wyważania, zwany „nierównowagą resztkową”. Ta nierównowaga nie jest wyczuwalna w większości typów pojazdów i konfiguracjach podwozia. Na każdej płaszczyźnie wyważania powinien być umieszczony tylko jeden obciążnik (Leister, 2015).

Im mniejsza masa obciążnika wyważającego na kole, tym mniejsze ryzyko nierównowagi resztkowej. Wąskie koła (np. motocyklowe), są wyważane tylko na jednej płaszczyźnie, natomiast obciążniki montowane są w centrum felgi. Koła do pojazdów ciężarowych oraz kompaktowe koła zapasowe z ograniczoną maksymalną prędkością nie są wyważane. Zazwyczaj niewyważenie statyczne jest bardziej odczuwalne na kierownicy niż niewyważenie dynamiczne (Nakajima, 2019).

4.3.4 Bicie promieniowe i bicie boczne

Odstępstwa wymiarowe opon są ściśle związane ze zmiennością sił występującą w ich ruchu tocznym. W przypadku ich wystąpienia pojawia się bicie promieniowe i boczne.


Bicie promieniowe to nieregularność w promieniu opony, czyli sytuacja, w której opona nie jest idealnie okrągła. Ugięcie lub wybrzuszenia boczne opisuje nieregularność w odległości między zewnętrzną stroną opony a środkową płaszczyzną koła, co prowadzi do wahań sił bocznych w centrum koła, które są następnie odczuwane przez pasażerów jako kołysanie lub szarpnięcia o odpowiednich cechach (Leister, 2015). Przeważnie stosowane są trzy następujące miary nieregularności wymiarowych:

- 1) Bicie promieniowe RRO – wahanie promienia opony mierzone prostopadłe do osi obrotu, wzdłuż obwodu opony na powierzchni bieżnika, w którym nie uwzględnia się wpływu rowków i wypływek na bieżniku gdy opona jest zamontowana na feldze; jest wyrażone w [mm] (Polski Komitet Normalizacyjny, 2002). Może być również określane jako „bicie względem osi symetrii” (*ang. centerline runout*) (Rodgers i Waddell, 2005).
- 2) Bicie boczne LRO - wahanie odległości między przyjętą płaszczyzną odniesienia (przyp. pomiar względny) prostopadłą do osi obrotu a danym bokiem opony, przy określonej odległości od wymienionej osi, w którym nie uwzględnia się wpływu liter i innego cechowania na boku, gdy opona jest zamontowana na feldze; jest wyrażone w [mm] (Polski Komitet Normalizacyjny, 2002). Wyznaczany najszerszym punkcie każdego boku opony (Rodgers i Waddell, 2005).
- 3) Najniższy / najwyższy punkt na boku opony (*ang. LRP depression / LRP bump*) – bezwzględny pomiar wysokości punktu największego lokalnego wybrzuszenia lub głębokości punktu największego lokalnego wgłębienia na boku opony.

4.3.5 Stożkowatość i ply steer


Siła boczna opony w obszarze jazdy na wprost jest podzielona na siłę boczną stożkową (*ang. conical lateral force*) - stożkowatość i tzw. siłę boczną strukturalną (*ang. structural lateral force*) – ply steer. Stożkowatość to składowa siły bocznej, określonej z efektu przesunięcia, która nie zmienia znaku wraz ze zmianą kierunku obrotów; wyrażona w niutonach [N] (Polski Komitet Normalizacyjny, 2002). Ply steer (tzw. efekt kątowy) to składowa siły bocznej, określonej z efektu przesunięcia, która zmienia znak wraz ze zmianą kierunku obrotów; wyrażona w niutonach [N] (Polski Komitet Normalizacyjny, 2002). W celu ich wyznaczenia wykonywane są pomiary opony w kierunku zgodnym z ruchem wskazówek zegara CW (*ang. clockwise*) oraz przeciwnym do ruchu wskazówek zegara CCW (*ang. counterclockwise*) (Rysunek 4.17.) (Leister, 2015).

Odnosząc się do wielkości opisujących jednorodność, stożkowatość (CON), nazywana także „efektem stożka” to tendencja opony do ściągania pojazdu (w lewo lub w prawo) z zamierzonej trajektorii. Ponieważ stożkowatość wykazuje właściwości podobne do siły bocznej LFV wynikającej z pochylenia koła (*ang. camber*), nazywa się ją również pseudopochyleniem (*ang. pseudo-camber*).



Rysunek 4.17. Zasada wyznaczania stożkowatości opon na maszynie do pomiaru jednorodności (opracowanie własne)


Wiąże się to z niesymetrycznym położeniem komponentów składowych opony względem jej osi (Rysunek 4.18.) (Rodgers i Waddell, 2005). Brak możliwości pomiaru symetrii wymiarowej materiałów użytych w już zwulkanizowanej oponie generuje potrzebę określenia stożkowatości, o której można powiedzieć, że jest wypadkową symetrii elementów opony.



Rysunek 4.18. Schematyczne przedstawienie zjawiska stożkowatości, gdzie obwód opony nie jest równy po obu jej stronach (opracowanie własne na podstawie Nakajima, 2019)

Stożkowatość opisuje zdolność opony do utrzymania toru jazdy wyznaczonego przez układ zawieszenia pojazdu. W zależności od rynku (kraju), dla którego przeznaczona jest dana opona, stosowana jest odpowiednia sekwencja nakładania opasań (Rysunek 4.19.). W oponach


radialnych do samochodów osobowych najczęściej występuje różnica 10-20 mm szerokości pomiędzy opasaniem 1 a opasaniem 2. Różnica w górnej części tego zakresu jest wykorzystywana np. do kompensacji wpływu asymetrycznej rzeźby bieżnika. Celem takiej procedury jest wymuszenie, aby pojazd zawsze był ściągany na pobocze. Jest to ważne ze względów bezpieczeństwa, np. w przypadku, gdy kierowca puści kierownicę lub zaśnie podczas jazdy. Dlatego stalowy kord szerszego opasania pierwszego jest zawsze skierowany w stronę pobocza. Dla prawidłowego funkcjonowania tego założenia i faktycznego zagwarantowania bezpieczeństwa podczas jazdy, stożkowatość musi być zapewniona na określonym poziomie. Co więcej, opona o zbyt wysokiej wartości stożkowatości będzie zużywać się nieregularnie (większa utrata masy mieszanki gumowej bieżnika po lewej stronie w porównaniu z prawą stroną opony lub odwrotnie), więc stożkowatość określa prawidłowy mechanizm zużycia opony podczas jej eksploatacji (Nakajima, 2019). Dlatego opona, która mieści się w granicach tej zmiennej wyjściowej, będzie wykazywać przewidywalne i bezpieczne zachowanie podczas użytkowania.



Rysunek 4.19. Układ opasania 1 i opasania 2 dla ruchu prawostronnego LHD (*ang. left-hand drive*) oraz lewostronnego RHD (*ang. right-hand drive*) (opracowanie własne)

W rzeczywistości istnieją dwie cechy opon, które powodują powstawanie resztkowej siły bocznej. Pierwszą z nich jest wspomniana już stożkowatość, wynikająca m.in. z nieznacznego przesunięcia opasań opony względem środka, co wynika z niedoskonałości procesu konfekcji. Powoduje to, że promień toczenia po stronie opony, w którą przesunięto opasanie, jest nieco mniejszy niż po stronie przeciwnej. Na skutek tego opona zachowuje się tak, jakby miała


przekrój stożkowy – generuje siłę boczną oraz moment prostujący, tak jakby była pochylona (zbieżność kątowa) w kierunku bardziej ograniczonej strony. Rozkład wartości pomiaru stożkowatości dla tego samego rozmiaru opon ma płaski charakter, jak pokazano schematycznie na Rysunku 4.20. Średnia wartość jest bliska zeru, chociaż z powodu asymetrii w procesie produkcyjnym może się nieco od niego różnić (Gent i Walter, 2006). W środowisku produkcyjnym wartość stożkowatości musi mieścić się w granicach $X \pm 40$ [N], gdzie X to wartość (zwykle bliska 0 [N]) określona na podstawie średniego pomiaru z pierwszej partii produkcyjnej nowego rozmiaru opony. Wielkość tej partii jest ustalana zgodnie z wymaganiami klienta (zazwyczaj 1000–5000 opon).



Rysunek 4.20. Rozkład wartości pomiarów stożkowatości i ply steer dla populacji jednego rozmiaru opon radialnych (czyli jednocześnie o tej samej konstrukcji) (Nakajima, 2019)

Kolejny efekt to ply steer, pojawiający się na skutek anizotropowej struktury opony (Gent i Walter, 2006). Ponieważ ply steer ma podobne właściwości do siły bocznej wynikającej z kąta znoszenia, nazywa się go również pseudo-znoszeniem (*ang. pseudo-slip*) (Nakajima, 2019). Powoduje, że opasania ulega ścinaniu w płaszczyźnie, gdy zostają zmuszone do spłaszczenia w obszarze kontaktu (styku z podłożem). Dodatkowe ścinanie w płaszczyźnie następuje również w wyniku zmian napięcia opasania w strefie kontaktu, co prowadzi do wygięcia obszaru styku i powstania resztkowego momentu prostującego ply steer (Rysunek 4.21.). Efekt ply steer wynika z konstrukcji opony. Gdy opasanie 1 ulega wygięciu w obszarze styku z nawierzchnią, na drugie opasanie (bliższe nawierzchni) działa siła ściskająca, w tym samym czasie na wewnętrzne, pierwsze opasanie działa siła rozciągająca. Te siły zewnętrzne wywołują naprężenia ścinające, które są takie same w pierwszym i drugim opasaniu. Rozkład wartości ply steer ma skupiony charakter, skoncentrowany wokół estymacji

projektowej, która może mieć jednak wysoką wartość, co ilustruje Rysunek 4.20. Podsumowując: rozrzut ply steer jest niewielki i zależy od konstrukcji opony, natomiast rozrzut stożkowatości jest duży i zależy w głównej mierze od procesu produkcyjnego. Ply steer powoduje efekt systematycznego odchylenia w produkcji opon, podczas gdy stożkowatość ma tutaj charakter losowy.




Rysunek 4.21. Przyczyna powstawania efektu ply steer (Nakajima, 2019)

Ważne jest również poznanie punktu przyłożenia tych sił. Strukturalna siła boczna (ply steer) jest przyłożona na większym ramieniu, niż siła boczna wynikająca z kąta poślizgu (LFV), zaś siła stożkowatości jest przyłożona na dużo mniejszym ramieniu (blisko punktu idealnego kontaktu koła z nawierzchnią). Zarówno stożkowatość, jak i siła boczna wynikająca z pochylenia LFV mają to samo, niemal zerowe ramię działania.

Dla zerowej wartości siły bocznej pojawia się moment prostujący RAT (*ang. Residual Aligning Torque*), który skutkuje momentem na kierownicy. Moment prostujący RAT, nazywany jest również momentem wyrównawczym (*ang. aligning torque*) – to moment obrotowy działający na koło, który „wyrównuje” jego kierunek tak, aby wracało do pozycji prostoliniowej. Powstaje głównie wskutek sił bocznych działających w obszarze styku opony z nawierzchnią i pomaga stabilizować kierunek jazdy. Dla zerowego momentu prostującego

z kolei pojawia się resztkowa siła boczna, która powoduje znoszenie pojazdu (przy puszczonej kierownicy) (Leister, 2015).

Rysunek 4.22. przedstawia różne sytuacje podczas jazdy. Jak pokazano na rysunku, siły wynikające z efektu ply steer (skrętu spowodowanego konstrukcją opasania opony) przy mocno trzymanej kierownicy powodują moment sterujący (na drążku kierowniczym) oraz siłę boczną. Dodatkowo, siły ply steer mają tendencję do ciągnięcia kierownicy w jedną stronę, gdy zostanie ona puszczona. Wówczas ustala się równowaga sił. Ponieważ zarówno siła ply steer, jak i siła boczna powstała w wyniku kąta poślizgu działają z tym samym ramieniem dźwigni, nie powstają siły wypadkowe. Pojazd porusza się na wprost (sytuacja I).




Rysunek 4.22. Mechanizmy ściągania pojazdu z toru ruchu na skutek działania zjawisk bocznych (opracowanie własne na podstawie Leister, 2015)

W przypadku siły stożkowej (*ang. conical force*), gdy kierownica jest trzymana, sytuacja jest podobna jak w przypadku *ply steer*, z tym że moment sterujący jest nieco mniejszy przy tej samej wartości siły. Jednakże, gdy kierownica zostanie puszczona, siła stożkowa – w przeciwieństwie do siły *ply steer* – spowoduje dryfowanie pojazdu. Dzieje się tak dlatego, że siły nie mogą osiągnąć równowagi przy zrównoważonych momentach, ponieważ siły stożkowa i boczna nie oddziałują w tym samym punkcie z powodu występującego kąta poślizgu (sytuacja II).

Tendencja do dryfowania spowodowana różnicami w stożkowatości jest proporcjonalna do tej siły i maleje wraz ze wzrostem pneumatycznego wyprzedzenia (*ang. pneumatic trail*). Pneumatyczne wyprzedzenie to odległość między punktem przyłożenia siły bocznej generowanej przez oponę a punktem styku opony z nawierzchnią (przesunięcie zwrotu siły). W rezultacie pojazd ma tendencję do dryfowania w kierunku dodatniej siły stożkowej (sytuacja III).

Moment działający na oponę przy zerowej sile bocznej RAT, powinien być na tyle duży, aby zrekompensować moment powstający zazwyczaj z siły działającej w dół (np. ciężaru pojazdu), pomnożonej przez pneumatyczne wyprzedzenie. Podobnie, siła wzdłużna (np. wynikająca z napędu lub hamowania) wraz z odpowiadającym jej ramieniem dźwigni powinna być również uwzględniona w bilansie momentów. Z uwagi na różne układy współrzędnych używane w pomiarach opon i pojazdów, omawiając zjawiska boczne należy stosować się do następującej konwencji znaków (Rysunek 4.23.) (Leister, 2015):


- 1) *Ply steer* działa w prawo, patrząc w kierunku jazdy – dlatego ma ujemny znak algebraiczny (-).
- 2) Moment RAT względem osi pionowej jest lewoskrętny.
- 3) Stożkowatość jest dodatnia (+), jeśli siły działają „do środka” pojazdu.



Rysunek 4.23. Konwencja znaków algebraicznych zjawisk bocznych
(opracowanie własne na podstawie Leister, 2015)


Szczególnie interesujące jest to, że dodatnia siła stożkowa zmniejsza kąt zbieżności na skutek efektów elasto-kinematycznych występujących w oponie.

Wartość stożkowatości jest bardzo istotna dla tendencji do znoszenia lub odchyłania pojazdu, jeśli wartości dla lewej i prawej jego strony się różnią. Ten efekt ma szczególne znaczenie gdy stan zużycia ogumienia staje się zauważalny. Pomiar stożkowatości pomaga ocenić jakość wykonania opony. Inną osobliwością jest fakt, że wartości stożkowatości zmieniają się w trakcie użytkowania pojazdu. Zmiany te zachodzą w stosunkowo symetryczny sposób, jeśli geometria podwozia jest poprawnie ustawiona. Oznacza to, że sama zmiana stożkowatości w trakcie eksploatacji nie ma negatywnego wpływu, co pokazano na Rysunku 4.24. Oba efekty się sumują, tzn. stożkowatości nie można "przesunąć na zewnątrz" przez zmianę centrowania opasania w oponie zwulkanizowanej, ale można ją zmienić w wyniku eksploatacji, np. poprzez wymianę opony.



Rysunek 4.24. Zmiana wartości stożkowatości w czasie eksploatacji opon zamontowanych na tym samym pojeździe; pomiary dotyczą opon: VL – przedniej lewej, VR - przedniej prawej, HL – tylnej lewej i HR – tylnej prawej (Leister, 2015)

Na Rysunku 4.25. został przedstawiony układ sił i momentów z założeniem, że pojazd porusza się na wprost a opony wykazują zjawiska ply steeru oraz stożkowatości. Kąt znoszenia pojazdu oznaczono jako β , zaś kąt skrętu przednich kół jako δ , natomiast pochylenie kół i zbieżność są zastosowane wyłącznie na osi przedniej.



Rysunek 4.25. Układ sił w pojeździe podczas jazdy na wprost (Nakajima, 2019)

Oznaczenia użyte na rysunku:

l , l_f , l_r – odległość od osi przedniej do osi tylnej oraz odległości od środka masy do osi przedniej i tylnej;

γ , δ , β – kąt zbieżności, kąt skrętu, kąt znoszenia pojazdu;

α_L , α_R – kąt znoszenia (lewe przednie koło, prawe przednie koło);

C_{fL} , C_{fR} – siła boczna (lewe przednie koło, prawe przednie koło);

M_{fL} , M_{fR} – moment prostujący (lewe przednie koło, prawe przednie koło);

C_t – siła boczna (tylne koło);

M_r – moment prostujący (tylne koło);

C_{Pf} , C_{Pr} – siła ply steer (przednie koło, tylne koło);

M_{Pf} , M_{Pr} – moment od siły plysteeru (przednie koło, tylne koło);
 C_{of} , C_{or} – siła stożkowatości (przednie koło, tylne koło);
 M_{of} , M_{or} – moment od siły stożkowości (przednie koło, tylne koło);
 K_f , K_r – sztywność boczna (przednie koło, tylne koło);
 T_f , T_r – sztywność momentu prostującego (przednie koło, tylne koło);
 C_t – siła od pochylenia koła.


Efekt ściągnięcia kierownicy zależy od właściwości opony, geometrii zawieszenia oraz pochylenia drogi, co zostało zobrazowane na Rysunku 4.26.). Dla przemysłu oponiarskiego oznacza to, że producenci samochodów ustalają limity dotyczące składowych siły ściągnięcia dla dostawców opon (aby móc pominąć ich wpływ podczas eksploatacji i w fazie projektowej pojazdu). Sytuacja z momentem prostującym ply steeru PRAT (*ang. plysteer residual aligning torque*) jest bardziej skomplikowana (M_{Pf} , M_{Pr} na Rysunku 4.25.). Każdy producent samochodów OEM (*ang. original equipment manufacturer*) ustala własny dopuszczalny zakres wartości momentu prostującego ply steeru, zgodnie ze swoją filozofią projektową. Niektórzy producenci samochodów wykorzystują PRAT do kompensacji pochylenia drogi, dlatego ich specyfikacje opon wymagają konkretnych wartości PRAT. Inni z kolei żądają zerowej wartości PRAT (w wąskiej tolerancji) i kompensują wpływ pochylenia drogi wyłącznie poprzez geometrię zawieszenia. Prowadzi to do kłopotliwych różnic w konstrukcji opon, które producenci opon muszą wprowadzać w identycznych produktach (tych samych rozmiarach opon), aby spełnić wymagania różnych producentów samochodów. Różnice te nie są widoczne dla sprzedawców opon ani dla kupujących. W rezultacie mogą wystąpić problemy z ściągnięciem pojazdu, gdy oryginalne opony OE (*ang. original equipment*) są zastępowane innymi, ponieważ opony dostępne na rynku wtórnym mogą nie spełniać właściwości określonych przez producenta auta. Może się wówczas zdarzyć, że samochód nie będzie jechał prosto bez korekty kierownicą, nawet jeśli zawieszenie jest prawidłowo ustawione według specyfikacji OEM (Nakajima, 2019).

Ogólny obraz zjawiska ściągnięcia pojazdu (Rysunek 4.26) jest związany nie tylko z samym samochodem, lecz także z oponami i nawierzchnią drogi w złożony sposób.

Do czynników związanych z samochodem należą (Nakajima, 2019):

- 1) Różnice w pochyleniu kół.
- 2) Różnice w wyprzedzeniu sworznia zwrotnicy.
- 3) Różnice w zbieżności kół (*ang. cross-scrub*).

Wymienione wyżej różnice wynikają z asymetrycznego ustawienia geometrii zawieszenia spowodowanego niedokładnością produkcji lub nieprawidłową konserwacją, a także średnią wartością wyprzedzenia sworznia zwrotnicy (czyli jak linia wyznaczona przez sworzeń zwrotnicy lub oś kolumny McPhersona jest pochylona względem pionu patrząc z boku pojazdu).



Rysunek 4.26. Przyczyny zjawiska ściągania pojazdów (opracowanie własne na podstawie Nakajima, 2019)

Do czynników związanych z oponami należą:

- 1) Kształt czoła opony.
- 2) Konstrukcja opasania (np. kąt opasania).
- 3) Wzór bieżnika (np. kąt ułożenia klocków i ich kształt).

Kształt czoła opony wpływa na rozkład naprężeń w opasaniach. Naprężenia te powodują skrętne odkształcenie opasania wokół osi pionowej, co prowadzi do powstania efektu ply steer. Kąt opasania również wpływa na ply steer - jeżeli wzór bieżnika o anizotropowej sztywności klocków zostanie przesunięty w jakimś kierunku lub ulegnie ściśnięciu, powstaje w nim moment obrotowy wskutek sprzężenia sił. Ten moment powoduje obrót opony wokół osi pionowej.

Ponadto, pochylenie nawierzchni drogi również powoduje ściąganie pojazdu wywołane składową siłą grawitacji.

Na zjawisko ściągania wpływają również czynniki tj.:

- 1) Prędkość.
- 2) Przyspieszenie.
- 3) Obciążenie.
- 4) Ciśnienie w oponach.
- 5) Zużycie bieżnika.
- 6) Opory układu kierowniczego.

Ogólnie rzecz biorąc, ze wszystkich wymienionych powyżej czynników, to właśnie konstrukcja i wzór bieżnika opony mają największy wpływ na zjawisko ściągania pojazdu (Nakajima, 2019).

4.3.6 Jednorodność przy wysokich prędkościach

Producenci samochodów (np. Mercedes-Benz Group AG oraz VOLVO) coraz częściej wymagają pomiaru HSU (Olazagoitia i in., 2020), który pozwala ocenić zachowanie opony podczas jej eksploatacji przy wyższych prędkościach, co bardziej odwzorowuje typowe użytkowanie. Pomiar eksperymentalne wykonywane na osi opony uwzględniają wpływ jej rezonansów (Gent i Walter, 2006). Ponieważ badane jest dynamiczne zachowanie opony, maszyny do pomiaru HSU muszą być starannie zaprojektowane, aby rezonanse samej maszyny nie zakłócały uzyskiwanych wyników pomiarów. Pomiar przeprowadzany jest w ustalonych warunkach ciśnienia i obciążenia opony, przechodząc krokowo od niskich do wysokich prędkości, przy których wyznacza się:

- 1) RH1, RH2 i RH3 – czyli pierwsze 3 harmoniczne siły promieniowej przy prędkościach 30, 120 i 180[km/h].
- 2) TH1, TH2 i TH3 – czyli pierwsze 3 harmoniczne sił stycznych przy prędkościach 120 i 180[km/h].

Siłami stycznymi są zarówno siła boczna, jak i siła wzdłużna – z tego względu dla tej samej prędkości i rzędu harmonicznej limit sił stycznych jest wyższy, niż w przypadku sił promieniowych. Niektóre maszyny rejestrują dodatkowo jeden lub więcej zmiennych momentów (Leister, 2015).

Zbieranie danych pomiarowych dotyczących wszystkich zjawisk przybliżonych w treści Rozdziału 4.3, umożliwia określenie jednorodności opon własnościami ją opisującymi, co ostatecznie pozwala na zapewnienie wyższego poziomu kontroli jakości wyrobu finalnego.

4.4 Testy stacyjne opon

Jednorodność jest ściśle powiązana z powodzeniem przeprowadzanych testów stacyjnych opon. Przykładowo w przypadku testów bieżnych wysokich i niskich prędkości, wszelkie niedoskonałości w budowie opony powodujące występowanie zmiennych sił promieniowych i bocznych wzmacniają się i prowadzą do powstawania wibracji, będących przyczyną nadmiernego nagrzewania się materiałów tworzących oponę lub niestabilności kierunkowej. Z tego względu, opona niejednorodna może nie przejść testu wysokich prędkości, gdyż występowanie wewnętrznych nierównomierności spowoduje jej przegrzewanie i w konsekwencji uszkodzenie. Jednorodność jest zatem jednym z czynników decydujących o trwałości opony ocenianej podczas tego typu testów. W trakcie testów homologacyjnych natomiast, dostawca musi wykazać, że produkt seryjny utrzymuje jakość zgodną z poziomem deklarowanym na jego etykiecie. Jednorodność powiązana z teorią wibracji, wpływa pośrednio m.in. na poziom emisji hałasu opony.

Testy stacyjne opon przeprowadzane są w następujących przypadkach:

- 1) Kwalifikacja nowego rozmiaru opon do produkcji masowej.
- 2) Nadzór produkcji masowej.
- 3) Zmiany specyfikacji opony.
- 4) Restart produkcji danego rozmiaru opony po okresie dłuższym niż 1 rok.

Wybrane testy opisywane w bieżącym podrozdziale zostały przeprowadzone specjalnie na potrzeby niniejszej dysertacji przez jej Autora dla opon wymienionych w Tabeli 4.3. Powodem wykonania testów było zbadanie konkurencyjnych rozwiązań w zakresie różnic występujących w konstrukcjach opon, bezpośrednio przekładających się na ich własności. Obecny podrozdział ma na celu wskazanie na liczbę i rodzaj wymagań, które opony muszą spełniać jako produkt.

Tabela 4.3. Opony poddane wybranym testom stacijnym (opracowanie własne)

Lp.	Rozmiar i rzeźba opony	Producent	Sezon
1	185/55 R16 87T WinterContact TS 870	Continental	zima
2	195/55 R16 87H Winter i*cept RS3 W462	Hankook	zima
3	205/55 R16 91H ALPIN 6	Michelin	zima
4	205/55 ZR16 (94Y) XL PILOT SPORT 4	Michelin	lato
5	225/50 R17 98W XL Advan Fleva V701	Yokohama	lato
6	225/50 R18 99W UltraContact NXT	Continental	lato
7	235/45 R18 98Y XL FR CrossClimate 2	Michelin	cały rok
8	235/55 R18 104H XL UltraGrip Performance+ SUV	Goodyear	zima

4.4.1 Analiza przekroju opony

Podstawowym i zarazem najczęściej przeprowadzanym testem jest analiza przekroju opony CSA (*ang. Cut Section Analysis*). Realizuje się ją na dwóch przekrojach (tzw. próbkach) opony zwulkanizowanej, natomiast próbki używane na jej potrzeby przygotowywane są w sposób uwzględniający poniższe zasady:

- 1) Żaden przekrój nie może zawierać wskaźników zużycia bieżnika TWI (*ang. tire wear index*).
- 2) Każdy przekrój należy wycinać w pewnej odległości od złącz bieżnika i wykładziny wewnętrznej.
- 3) Każdy przekrój należy wycinać w sposób, który pozwoli wykonać pełen pomiar barku opony po obu mierzonych stronach.
- 4) Przekroje opon mierzy się zawsze mając stronę numerem seryjnym DOT po lewej stronie (tzw. strona seryjna – SS, *ang. serial side*). Stronę z numerem seryjnym DOT należy przed wykonaniem przekroju naznaczyć przy pomocy białej kredki w okolicy drutówki.
- 5) Każdy przekrój należy wyciąć tak, aby miał od 20 do 50[mm] szerokości i żeby przekroje były odległe od siebie o około 180° na obwodzie opony. Powierzchnie przekrojów powinny być oszlifowane.

Obecnie analizę przekroju przeprowadza się na wysokiej jakości skanach próbek opon przy pomocy oprogramowania przeliczającego piksele na milimetry na podstawie

współczynnika skali zadanemu skanerowi. Pomiarowi podlegają grubości warstw i materiałów opony oraz odległości pomiędzy zakończeniami materiałów widocznych na przekroju. Ze względu na istotność, punkty pomiarowe podzielone są na 3 grupy, które zostały przedstawione w Tabeli 4.4.

Tabela 4.4. Ważności punktów CSA (opracowanie własne)


Ranking	Ważność	Opis
B	krytyczny	Punkt może mieć wpływ na osiągi opony i/lub na zgodność z wymaganiami klienta.
C	nie krytyczny	Brak wpływu osiągi opony i/lub na zgodność z wymaganiami klienta.
brak	nie krytyczny	Punkty, które nie mają przypisanej tolerancji, a ich pomiary są gromadzone z uwagi na pewne funkcje techniczne (np. grubości głównych obszarów opony w celu doboru najodpowiedniejszego cyklu wulkanizacyjnego). Wartości tych punktów wyznaczane są na etapie kwalifikacji i traktuje się je jako referencyjne w nadzorze regularnej produkcji. Na ich podstawie nie wymaga się jednak podejmowania decyzji dotyczących np. konieczności zmian specyfikacji opony.

Do wyznaczenia niektórych punktów pomiarowych niezbędne jest CTLO (*ang. cured tire layout*) z naniesionymi indywidualnie dla każdego rozmiaru opony punktami odniesienia. Stanowi ono także pierwszą weryfikację, czy opona została wyprodukowana zgodnie z narzuconymi założeniami. Przykładowe CTLO zostało przedstawione na Rysunku 4.27.

Dla prawidłowego przeprowadzenia pomiarów przekroju poprzecznego opony na CTLO zaznaczone są strony seryjna SS (*ang. serial side*) oraz przeciwna do seryjnej OSS (*ang. opposite to serial side*). Punkty odniesienia mają następujące znaczenie:

- 1) CL (*ang. central line*) – linia centralna przekroju poprzecznego. W przypadku symetrycznych rzeźb bieżnika stanowi ona jednocześnie oś symetrii przekroju. Jest odniesieniem do pomiarów zakończeń materiałów znajdujących się w obszarze korony bieżnika, czyli warstwy spiralnej i opasań.

- 2) S (*ang. shoulder*) – punkt na barku bieźnika, którego odległość od linii centralnej ustalana indywidualnie w zależności o szerokości opony oraz rzeźby bieźnika.
- 3) B (*ang. buttress*) – miejsce barku opony, w którym podczas wulkanizacji przebiega linia podziału formy (MPL, *ang. mold partition line*), czyli dochodzi do styku płyt bocznych z segmentami bieźnika.
- 4) SW (*ang. section width*) – najszersze miejsce przekroju opon nieposiadających rantu ochronnego. W tym punkcie dochodzi do pomiaru grubości gumy boku.
- 5) L – umiejscowiony tuż poniżej ryski centrującej, będący zazwyczaj jednocześnie miejscem linii podziałowej mieszanek gumowych SW/AGS boku.
- 6) H (*ang. heel*) – połowa szerokości stopki. Stanowi odniesienie do pomiarów zakończeń materiałów znajdujących się po zewnętrznej stronie osnowy np. wysokości wypełniacza drutowki, wywinięcia osnowy/osnów (dla konstrukcji SOT), górnego i dolnego punktu linii podziałowej mieszanek SW/AGS boku, zakończeń flippera i chafera (jeśli występują).
- 7) BT (*ang. bead toe*) – zakończenie noska drutowki. Stanowi odniesienie do pomiarów zakończeń materiałów znajdujących się po wewnętrznej stronie osnowy np. wykładziny wewnętrznej, gumy AGS i chafera (jeśli występuje).



Rysunek 4.27. Przykładowe CTLO z naniesionymi punktami odniesienia.


Na CTLO określona jest również wartość TTP (*ang. toe to toe periphery*), czyli odległość pomiędzy noskami drutowki mierzona po linii osnowy. Wartość ta stanowi podstawę do określenia rozstawu drutowek BLW (*ang. bead lock width* lub BSEE, *ang. bead set external*

edge), który jest najważniejszym parametrem procesu konfekcji opon, decydującym o doborze szerokości wykorzystywanych materiałów w danym rozmiarze opon oraz o jego napięciu osnowy.


Na Rysunkach 4.28. – 4.35. przedstawiono przekroje opon wymienionych w Tabeli 4.3. przygotowane w sposób zgodny ze standardem wykonywania próbek do analizy przekroju poprzecznego opony.




Rysunek 4.28. Przekrój poprzeczny opony 185/55 R16 87T Continental WinterContact TS 870
(opracowanie własne)




Rysunek 4.29. Przekrój poprzeczny opony 195/55 R16 87H Hankook Winter i*cept RS3 W462
(opracowanie własne)




Rysunek 4.30. Przekrój poprzeczny opony 205/55 R16 91H Michelin ALPIN 6 (opracowanie własne)



Rysunek 4.31. Przekrój poprzeczny opony 205/55 ZR16 (94Y) XL Michelin PILOT SPORT 4 (opracowanie własne)




Rysunek 4.32. Przekrój poprzeczny opony 225/50 R17 98W XL Yokohama Advan Fleva V701 (opracowanie własne)



**Rysunek 4.33. Przekrój poprzeczny opony 225/50 R18 99W Continental UltraContact NXT
(opracowanie własne)**



**Rysunek 4.34. Przekrój poprzeczny opony 235/55 R18 104H XL Goodyear UltraGrip Performance+ SUV
(opracowanie własne)**



**Rysunek 4.35. Przekrój poprzeczny opony 235/45 R18 98Y XL FR Michelin CrossClimate 2
(opracowanie własne)**

4.4.2 Odcisk rzeźby bieżnika

Odcisk rzeźby bieżnika (*ang. footprint*) pobierany jest z opony w celu określenia kształtu i powierzchni jej styku z podłożem. Przekłada się to bezpośrednio na jej przyczepność oraz opory toczenia. Na etapie wdrożenia nowego rozmiaru opony, odcisk rzeźby jest wyznaczany aby wprowadzić ewentualne zmiany szerokości opasań, konstrukcji warstwy spiralnej lub surowego profilu bieżnika dla uzyskania początkowo założonego efektu. Podczas dokonywania pomiaru, opona zakładana jest na felgę dobraną zgonie z (ETRTO, 2025) lub (WdK, 2025) w zależności od wymagań rynku / klienta. Parametry pomiaru, czyli ciśnienie i obciążenie najczęściej dobierane są zgodnie z Tabelą 4.5. W przypadku niektórych rozmiarów opon narzucone są wyjątkowe warunki pomiarowe (o czym decyduje centrum techniczne).

Tabela 4.5. Dobór parametrów pomiaru odcisku rzeźby bieżnika opon radialnych do samochodów osobowych (opracowanie własne na podstawie materiałów własnych przedsiębiorstwa)

Parametr	Opony standardowe	Opony wzmocnione
Ciśnienie [bar]	1.9 dla szerokości 195 i poniżej	2.3 dla wszystkich szerokości
	2.0 dla szerokości 205 i powyżej	
Obciążenie [kg]	88% indeksu nośności opony	

Na obszar bieżnika, który ma zostać odcisnięty nakłada się tusz przy pomocy gąbki. Odciski pobiera się z trzech obszarów oddległych od siebie o 120° unikając przy tym połączeń segmentów formy wulkanizacyjnej. Pobrane na kartach do odcisków „stemple” obrysowuje się konturem, po czym mierzone są długości styku (w centrum i na barkach). Na tej podstawie

używając Równań 4.3 lub 4.4 obliczany jest końcowy wynik testu, czyli wskaźnik prostokątności. Linie na których mierzy się długości styku w zależności od kształtu odcisku zostały schematycznie przedstawione na Rysunku 4.36.

Obliczanie wskaźnika prostokątności dla odcisku o kształcie zbliżonym do okręgu lub prostokąta:

$$\text{Wskaźnik prostokątności} = (B1 + B2)/2A * 100 [\%] \quad (4.3)$$

gdzie:

A – długość odcisku na linii centralnej;

B1, B2 – długości odcisku na barkach.


Obliczanie wskaźnika prostokątności dla odcisku o kształcie motyla:

$$\text{Wskaźnik prostokątności} = (D1 + D2)/(C1 + C2) * 100 [\%] \quad (4.4)$$

gdzie:

C1, C2 – długości odcisku w jego najwęższych miejscach;

D1, D2 – długości odcisku w najszerszych miejscach na barkach.



Rysunek 4.36. Linie pomiaru długości styku dla obu wariantów kształtu odcisku rzeźby bieżnika


W Tabeli 4.6. przedstawiono wyniki pomiaru wskaźnika prostokątności wszystkich opon poddanych badaniom. Zazwyczaj osiąga on wartości bliższe 100% dla opon sportowych, gdzie priorytetem jest osiągnięcie wysokiej przyczepności. W przypadku opon o standardowym zastosowaniu w ruchu drogowym, wartość wskaźnika prostokątności zawiera się najczęściej

w przedziale 70-85%, ponieważ obecnie opony tego typu projektowane są w taki sposób, aby charakteryzowały się jak najniższymi oporami toczenia przy zachowaniu zadowalającej przyczepności do podłoża.


Tabela 4.6. Wskaźnik prostokątności badanych opon (opracowanie własne)

Lp.	Nazwa opony	Wskaźnik prostokątności [%]
1	185/55 R16 87T Continental WinterContact TS 870	83.39
2	195/55 R16 87H Hankook Winter i*cept RS3 W462	84.91
3	205/55 R16 91H Michelin ALPIN 6	83.30
4	205/55 ZR16 (94Y) XL Michelin PILOT SPORT 4	79.76
5	225/50 R17 98W XL Yokohama Advan Fleva V701	79.87
6	225/50 R18 99W Continental UltraContact NXT	78.37
7	235/45 R18 98Y XL FR Michelin CrossClimate 2	82.11
8	235/55 R18 104H XL Goodyear UltraGrip Performance+ SUV	74.20


Na Rysunkach 4.37. – 4.44. przedstawiono zestawienia odcisków wykonanych na potrzeby testu z fotografiami badanych rzeźb bieżników.



Rysunek 4.37. Odcisk oraz fotografia rzeźby bieżnika opony 185/55 R16 87T Continental WinterContact TS 870 (opracowanie własne)



**Rysunek 4.38. Odcisk oraz fotografia rzeźby bieżnika opony 195/55 R16 87H
Hankook Winter i*cept RS3 W462 (opracowanie własne)**



**Rysunek 4.39. Odcisk oraz fotografia rzeźby bieżnika opony 205/55 R16 91H Michelin ALPIN 6
(opracowanie własne)**



**Rysunek 4.40. Odcisk oraz fotografia rzeźby bieżnika opony 205/55 ZR16 (94Y) XL
Michelin PILOT SPORT 4 (opracowanie własne)**



**Rysunek 4.41. Odcisk oraz fotografia rzeźby bieżnika opony 225/50 R17 98W XL
Yokohama Advan Fleva V701 (opracowanie własne)**



**Rysunek 4.42. Odcisk oraz fotografia rzeźby bieżnika opony 225/50 R18 99W
Continental UltraContact NXT (opracowanie własne)**



**Rysunek 4.43. Odcisk oraz fotografia rzeźby bieżnika opony 235/45 R18 98Y XL FR
Michelin CrossClimate 2 (opracowanie własne)**



**Rysunek 4.44. Odcisk oraz fotografia rzeźby bieżnika opony 235/55 R18 104H XL
Goodyear UltraGrip Performance+ SUV (opracowanie własne)**

4.4.3 Testy siły i ciśnienia osadzenia stopki

Test siły osadzenia stopki (rozciąganie stopki, *ang. bead fit force*) (WdK, 2025) przeprowadza się w celu oceny siły kompresji drutówki na obręczy. Niezachowanie jej na odpowiednim poziomie może wiązać się z utratą powietrza i/lub spadaniem opony z obręczy w wyniku działania wysokich momentów siły w czasie utrzymywania trakcji

lub hamowania pojazdu. Pomiar siły osadzenia stopki przeprowadza się w następujący sposób na oponach, dla których upłynęło co najmniej 6 dni od momentu ich wulkanizacji:

- 1) Nastawić maszynę pomiarową z zamontowanymi odpowiednimi segmentami obręczy (dopasowanymi do całej opony).
- 2) Wyczyścić obszary drutówki po obu stronach opony przy użyciu szmatki nasączonej alkoholem, a następnie wysuszyć inną suchą szmatką.
- 3) Przed ułożeniem opony w celu pomiaru SS i przed ułożeniem w celu pomiaru OSS wyczyścić dokładnie segmenty obręczy na obszarze, który ma kontakt z oponą.
- 4) Nałożenie na obszar drutówki opony testowej talku, smaru lub brak obecności jakiegokolwiek substancji zależny jest od indywidualnych wymagań klienta.
- 5) Ułożyć oponę stroną, która ma być mierzona do dołu, w kontakcie z segmentami obręczy.
- 6) Wykonać „fazę rozciągania” do określonej średnicy (zwiększenie średnicy obręczy o 0.8mm, która stanowi punkt wyjściowy do ustawiania segmentów obręczy w celu przeprowadzania pomiarów).
- 7) Cofnąć segmenty obręczy do ujemnych wartości przesunięcia i dokonać pomiaru (punkt pomiarowy ‘-0.29mm’).
- 8) Wykonać pomiar siły osadzenia stopki rozszerzając segmenty obręczy przy określonej prędkości testowej aż do najwyższego punktu pomiarowego średnicy (punkt pomiarowy ‘+0.38mm’).

Wyniki pomiaru siły osadzenia stopki wszystkich opon poddanych badaniom zostały przedstawione w Tabeli 4.7. Dla opon dedykowanych na rynek wtórny o rozmiarze 15-20” przyjmuje się, że wartość siły osadzania stopki dla punktu pomiarowego ‘-0.29mm’ powinna być wyższa niż 1800N (tzw. limit bezpieczeństwa).

Tabela 4.7. Wyniki pomiarów siły osadzenia stopki dla wszystkich wymaganych punktów pomiarowych badanych opon (opracowanie własne)

Lp.	Nazwa opony	Siła osadzenia stopki [N]			
		-0.29mm / SS	-0.29mm / OSS	+0.38mm / SS	+0.38mm / OSS
1	185/55 R16 87T Continental WinterContact TS 870	2060	1930	3340	3180
2	195/55 R16 87H Hankook Winter i*cept RS3 W462	2100	2150	3310	3350
3	205/55 R16 91H Michelin ALPIN 6	3340	3100	4670	4380
4	205/55 ZR16 (94Y) XL Michelin PILOT SPORT 4	3380	3010	4610	4170
5	225/50 R17 98W XL Yokohama Advan Fleva V701	3220	2700	5180	4440
6	225/50 R18 99W Continental UltraContact NXT	2980	2750	4240	3990
7	235/45 R18 98Y XL FR Michelin CrossClimate 2	4330	4070	5750	5530
8	235/55 R18 104H XL Goodyear UltraGrip Performance+ SUV	4650	4580	6190	6120

Test ciśnienia osadzenia stopki (*ang. bead seating pressure*) przeprowadza się natomiast w celu oceny montowalności opony na przewidzianą obręcz zgodną z wymaganiami klienta dla rynku OE lub (ETRTO, 2025) dla rynku wtórnego. Pomiar realizowany jest według poniżej procedury, na oponach które nigdy wcześniej nie zostały poddane żadnym testom, ani operacji montowania na obręcz / demontowania z obręczy:

- 1) Zamontować oponę na obręcz, a przed napompowaniem opony należy upewnić się, że jest obecny rdzeń zaworu.
- 2) Napompować oponę „jednym strzałem” do pierwszego osadzenia stopki w dolnej drutowce opony.
- 3) Następnie dopompowywać oponę zwiększając ciśnienie stopniowo co 0.2[bar] czekając po 5[s] pomiędzy poszczególnymi krokami do kolejnego osadzenia stopki (wynik pomiaru).

Dla większości klientów wartości limitów ciśnienia osadzenia stopki zawierają się w zakresie $3.0 \div 3.5$ [bar].

4.4.4 Testy bieżne opon (wysokich i niskich prędkości)

W niniejszym podrozdziale opisano zasady ogólnego podejścia do testów bieżnych opon. W zależności od specyficznych wymagań danego klienta warunki testów (temperatura podczas badania, ciśnienie opon, kondycjonowanie itp.) mogą się nieznacznie różnić. Wygląd testu bieżnego został zilustrowany na Rysunku 4.45.

Podstawowymi warunkami testów niskich prędkości są:

- 1) Szerokość i profil obręczy (felgi) pomiarowej.
- 2) Średnica bębna pomiarowego.
- 3) Temperatura podczas badania w komorze / pomieszczeniu w którym przeprowadzany będzie test (zazwyczaj 38 ± 3 [°C]).
- 4) Kondycjonowanie co najmniej 3[h] w temperaturze pomieszczenia testów.
- 5) Ciśnienie opony (zazwyczaj 3.0[bar] dla wszystkich rodzajów opon).
- 6) Prędkość (najczęściej 60[km/h]).
- 7) Obciążenie (zazwyczaj $180 \div 200\%$ indeksu nośności opony).



Rysunek 4.45. Opona podczas testu bieżnego (materiały własne przedsiębiorstwa)

Opona podczas takiego testu jest sprawdzana wizualnie i manualnie co najmniej raz na dobę. Test ulega zakończeniu z pozytywnym rezultatem w momencie, gdy opona osiągnie wymagany limit przejeżdżając zadany dystans, który najczęściej wynosi 8000[km]. Test kończy się wynikiem negatywnym w przypadku wcześniejszego stwierdzenia (przed osiągnięciem limitu) zewnętrznej wady wizualnej np. rys, pęknięć, rozwarstwień, separacji warstw lub wybrzuszeń. Testy niskich prędkości pozwalają zatem na ocenę wytrzymałości opony w warunkach skrajnego obciążenia, stosunkowo wysokiej temperatury atmosferycznej oraz nienaturalnie wysokiego ciśnienia roboczego. Takie postępowanie ma za zadanie zasymulować (w znacznie krótszym czasie) proces zużycia opony podczas wieloletniej eksploatacji.

Natomiast podstawowymi warunkami testów wysokich prędkości są:

- 1) Szerokość i profil obręczy (felgi) pomiarowej.
- 2) Średnica bębna pomiarowego.
- 3) Temperatura podczas badania w komorze / pomieszczeniu w którym przeprowadzany będzie test (zazwyczaj $38\pm 3^{\circ}\text{C}$).
- 4) Kondycjonowanie co najmniej 3[h] w temperaturze pomieszczenia testów.
- 5) Ciśnienie opony - dobierane w zależności od rodzaju opony (standardowa / wzmocniona) i indeksu prędkości).
- 6) Obciążenie (zazwyczaj 80% indeksu nośności opony).

Test polega na krokowym zwiększaniu prędkości po upływie czasu określonego dla danego etapu. W Tabeli 4.8. przedstawiono przykładowe postępowanie dla indeksu prędkości V (dla którego 240km/h to maksymalna prędkość, przy której opona jest zdolna do bezpiecznego przenoszenia obciążenia określonego przez indeks nośności).

W celu rzetelnej oceny, trwający dłużej krok 4 służy wyrównaniu temperatury wewnątrz opony tuż przed osiągnięciem prędkości narzuconej przez jej indeks. Pozwala to na uniknięcie wystąpienia defektów wywołanych w efekcie szoku cieplnego. Jeśli opona osiągnie krok 6 bez ujawnienia jakiegokolwiek wady, test można uznać jako zaliczony.

Tabela 4.8. Przykładowy przebieg testu wysokiej prędkości dla indeksu V
(opracowanie własne na podstawie materiałów wewnętrznych przedsiębiorstwa)

Krok 1	Czas [min]	10
	Prędkość [km/h]	120
Krok 2	Czas [min]	10
	Prędkość [km/h]	150
Krok 3	Czas [min]	10
	Prędkość [km/h]	180
Krok 4	Czas [min]	60
	Prędkość [km/h]	220
Krok 5	Czas [min]	10
	Prędkość [km/h]	230
Krok 6	Czas [min]	10
	Prędkość [km/h]	240
Krok 7	Czas [min]	10
	Prędkość [km/h]	250
Kontynuować do uzyskania defektu	Czas [min]	+10
	Prędkość [km/h]	+10

4.4.5 Wyznaczenie oporów toczenia opon

Opór toczenia opon wyznacza się metodą momentu obrotowego zgodnie z wymaganiami opisanymi w (ISO, 2018). Przed rozpoczęciem testu oporu toczenia należy zapewnić, że zostały spełnione następujące warunki:

- 1) Badanie może być przeprowadzone tylko i wyłącznie na oponie, która nigdy wcześniej nie była używana do testu podnoszącego jej temperaturę powyżej wartości generowanej podczas testów oporu toczenia i nie powinna być wcześniej wystawiona na działanie temperatury wyższej niż 40[°C].
- 2) Zestaw montażowy musi być wyważony.
- 3) Wyływyki w obszarze bieżnika powinny zostać otrymowane, a dopuszczalne pozostałości wyływek powinny mieć wysokość < 0.5[mm].
- 4) Należy używać obręczy pomiarowej dobranej wg (ETRTO, 2025) charakteryzującej się następującą dokładnością – maks. 0.5[mm] RRO i maks. 0.5[mm] LRO.

- 5) Kondycjonowanie – opona musi być zamontowana na wymaganą obręcz testową i zostać napompowana do wymaganego ciśnienia testowego – tak przygotowany zestaw powinien być kondycjonowany przez minimum 3[h] w temperaturze pokojowej 25[°C].
- 6) Po kondycjonowaniu należy dopompować oponę do ciśnienia testowego i sprawdzić je 10[min] po pompowaniu (tolerancja to punkt wyjściowy ciśnienia ± 3 [kPa]); należy jednak unikać przypadków, w których konieczne jest zwiększenie ciśnienia w oponie (np. w sytuacji gdy punkt wyjściowy wynosi 210[kPa] i otrzymano rzeczywiste 207[kPa] po 3[h] kondycjonowania – nie należy zwiększać ciśnienia).
- 7) Prędkość – 80[km/h].
- 8) Obciążenie kontaktowe – 100[N] (dla pomiaru niepożądaney straty).
- 9) Wymagana temperatura pomieszczenia testów to 25[°C] $\pm$ 2.5[°C] – mierzona w odległości nie mniejszej niż 0,15[m] i nie większej niż 1[m] od boku opony.
- 10) Obciążenie – 80% indeksu nośności.
- 11) Czas dotarcia – 30[min].

Procedura testu:

- 1) Dotarcie powinno trwać 30[min] przy testowej prędkości, obciążeniu oraz ciśnieniu.
- 2) Po dotarciu, utrzymując oponę w tej samej prędkości testowej i z tym samym obciążeniem zmierzyć opór toczenia $RR_{80\%}$.
- 3) Po pomiarze $RR_{80\%}$ dochodzi do zmiany obciążenia testowego na kontaktowe przy utrzymaniu opony w tej samej prędkości testowej, po czym dochodzi do pomiaru oporu toczenia szacując niepożądaną stratę RR_{100N} .
- 4) Zgodnie z Równaniem 4.5 opór toczenia opony będzie stanowił różnicę pomiędzy oporem toczenia zmierzonym w warunkach obciążenia testowego a oporem toczenia wynikającym z niepożądaney straty:

$$RR = RR_{80\%} - RR_{100N} \text{ [N]} \quad (4.5)$$

- 5) Następnie oblicza się współczynnik oporu toczenia RRc według Równania 4.6:

$$RRc = RR / \text{Obciążenie} \text{ [N / kN]} \quad (4.6)$$

- 6) Ostatecznie wyznacza się klasę efektywności paliwowej zgodnie z Tabelą 4.9. W literaturze często spotykaną jednostką dla RRc jest również tożsama [kg/t]. Wybór jednostki zależy od sposobu zapisu obciążenia przyjętego w toku obliczeń,

który narzucony jest przez oprogramowanie wykorzystywanej maszyny pomiarowej (Wiegand, 2016).

Tabela 4.9. Wartości graniczne współczynnika oporu toczenia dla danej klasy efektywności paliwowej (opracowanie własne na podstawie UNECE, 2025)

Klasa efektywności paliwowej	Wartość graniczna RRc [N/kN]
A	≤ 6.5
B	≤ 7.7
C	≤ 9.0
D	≤ 10.5
E	≥ 10.6

Współczynniki oporu toczenia wyznaczone dla przebadanych opon zostały zebrane w Tabeli 4.10.

Tabela 4.10. Współczynnik oporu toczenia RRc badanych opon (opracowanie własne)

Lp.	Nazwa opony	Współczynnik oporu toczenia RRc [N/kN]	Klasa efektywności paliwowej
1	185/55 R16 87T Continental WinterContact TS 870	8.1	C
2	195/55 R16 87H Hankook Winter i*cept RS3 W462	9.3	D
3	205/55 R16 91H Michelin ALPIN 6	8.6	C
4	205/55 ZR16 (94Y) XL Michelin PILOT SPORT 4	8.4	C
5	225/50 R17 98W XL Yokohama Advan Fleva V701	7.2	B
6	225/50 R18 99W Continental UltraContact NXT	6.1	A
7	235/45 R18 98Y XL FR Michelin CrossClimate 2	7.3	B
8	235/55 R18 104H XL Goodyear UltraGrip Performance+ SUV	8.0	C

4.4.6 Opór elektryczny opon

Ze względu na to, że bazą stosowanych obecnie w przemyśle oponiarskim mieszanek gumowych dedykowanych na kapę bieżnika jest nieprzewodząca ładunki elektryczne

krzemionka, konieczny jest pomiar oporu elektrycznego opon. Polega on na przyłożeniu elektrody dodatniej omomierza do mieszanki antenowej bieżnika, natomiast elektrodę ujemną zaciska się na drutówce opony. Dla zapewnienia odpowiedniego poziomu bezpieczeństwa każda opona powinna charakteryzować się oporem elektrycznym $\leq 50 \text{ [M}\Omega\text{]}$.

4.4.7 Własności fizyczne mieszanki bieżnika

Dla zagwarantowania przyczepności opony, jej trwałości oraz przewidywalności zachowania w różnych warunkach drogowych i temperaturowych na odpowiednim poziomie, wyznacza się następujące własności fizyczne mieszanki bieżnika:

- 1) Twardość.
- 2) Moduły przy określonym wydłużeniu.
- 3) Wytrzymałość na rozciąganie.
- 4) Wydłużenie całkowite przy zerwaniu próbki.

W Tabeli 4.11. porównano wyniki pomiarów twardości mieszanki bieżnika badanych opon. Zgodnie z wewnętrzną procedurą przedstawione rezultaty to średnia z 6 pomiarów dla każdej opony.

Tabela 4.11. Twardość mieszanki bieżnika badanych opon (opracowanie własne)

Lp.	Nazwa opony	Twardość [°Shore A]	Sezon
1	185/55 R16 87T Continental WinterContact TS 870	64.7	zima
2	195/55 R16 87H Hankook Winter i*cept RS3 W462	70.7	zima
3	205/55 R16 91H Michelin ALPIN 6	66.5	zima
4	205/55 ZR16 (94Y) XL Michelin PILOT SPORT 4	68.7	lato
5	225/50 R17 98W XL Yokohama Advan Fleva V701	68.9	lato
6	225/50 R18 99W Continental UltraContact NXT	66.6	lato
7	235/45 R18 98Y XL FR Michelin CrossClimate 2	65.5	cały rok
8	235/55 R18 104H XL Goodyear UltraGrip Performance+ SUV	66.7	zima

W procesie wytwarzania w fabryce opon największy udział ilościowy w stosunku do wszystkich produkowanych mieszanek gumowych stanowi mieszanka bieżnika.

Z tego względu szczególnie istotne jest ciągle utrzymanie jej jakości na wysokim poziomie. Szybka identyfikacja odchyłeń od ustalonych limitów właściwości fizycznych, pozwala na bieżąco monitorować stabilność i efektywność procesu mieszania i wulkanizacji. Dzięki temu możliwe jest wdrożenie działań korygujących na stosunkowo wczesnym etapie, co minimalizuje ryzyko wycofania partii opon zawierających wadliwą mieszankę.

4.5 Testy homologacyjne

W zależności od rynku (kraj) na który dedykowana jest opona, musi ona przejść dodatkowe testy w celu otrzymania odpowiedniej certyfikacji (homologacji). Pakiet testów składających się na daną homologację, zawiera zazwyczaj indywidualne podejście do warunków (głównie: temperatury podczas przeprowadzania pomiaru, ciśnienia opony, limitów i zakresu tolerancji rezultatów) przeprowadzania wymienionych niżej pomiarów:

- 1) Wymiarów fizycznych opony, na które składają się:
 - a) Średnica całkowita opony OD (*ang. overall diameter*) – mierzona pośrodku napompowanej opony (wzdłuż linii centralnej) lub blisko linii centralnej (w przypadku bieżnika z rowkiem centralnym).
 - b) Szerokość całkowita przekroju OW (*ang. overall width*) – liniowa odległość pomiędzy zewnętrznymi stronami boków napompowanej opony włączając oznaczenia, dekoracje, ranty ochronne i żebra.
 - c) Szerokość przekroju SW (*ang. section width*) – liniowa odległość pomiędzy zewnętrznymi stronami boków napompowanej opony wyłączając wypukłości związane z oznaczeniami, dekoracjami, rantami ochronnymi i żebrami.
 - d) Głębokość rowków rzeźby bieżnika SK (*ang. skid depth*) – mierzona w najgłębszym rowku najbliższym linii centralnej napompowanej opony.
 - e) Wskaźnik zużycia bieżnika TWI (*ang. tire wear index*) - poprzeczne mostki w rowkach bieżnika mające na celu wizualne wskazanie stopnia zużycia bieżnika. Pomiar głębokości TWI otrzymuje się z różnicy pomiędzy głębokością rowka bieżnika (SK) i głębokością rowka mierzoną na szczycie wskaźnika zużycia bieżnika.
- 2) Ciśnienia osadzania stopki.
- 3) Testów bieżnych wysokich i niskich prędkości.

Niektóre homologacje uwzględniają dodatkowe specyficzne testy, czego przykładem jest amerykańska DOT zawierająca w sobie test przebicia opony (*ang. plunger*). Opona założona

na specjalną maszynę pomiarową (Rysunek 4.46.) w celu uzyskania pozytywnego rezultatu, powinna ulec przebiciu przez znormalizowany wgłębnik, dopiero po przekroczeniu siły do niego przyłożonej o wartości przekraczającej 5200N. Informacja o homologacji jaką posiada dana opona, zawsze uwzględniana jest w napisach naniesionych w obszarze boku (tzw. stamping).



Rysunek 4.46. Maszyna do przeprowadzania testu przebicia opony (materiały własne przedsiębiorstwa)

Reasumując, przedstawione w niniejszym rozdziale zagadnienia dotyczące eliminacji defektów, spełniania wymagań klienta, zapewnienia jednorodności opon na odpowiednim poziomie oraz procedur testowych i homologacyjnych wskazują, że mimo osiągnięcia wysokiego poziomu dojrzałości technologicznej, obszary te wciąż pozostają przedmiotem intensywnych badań i doskonalenia. Dążenie do dalszej poprawy jakości, niezawodności i bezpieczeństwa opon stanowi istotny impuls rozwojowy. Determinuje to konieczność poszukiwania innowacyjnych rozwiązań w zakresie materiałów, procesów produkcyjnych oraz metod kontroli. W konsekwencji, dalsza część pracy została poświęcona analizie kierunków badań opon samochodowych, które wyznaczają perspektywy dla przyszłych działań badawczo-rozwojowych w tym obszarze.


5. Współczesne kierunki badań opon samochodowych

Rozwiązania wdrażane w nowoczesnej logistyce i transporcie muszą opierać się na określonym poziomie wydajności komponentów. Przykładem jest przejęcie TomTom Telematics przez korporację Bridgestone w celu rozpoczęcia świadczenia nowego typu usług (Bridgestone Europe Completes Acquisition of TomTom Telematics, 2024). W oparciu o bazę danych doświadczeń klientów flotowych, przewidywaną żywotność opon, a także rejestrację przebiegu pojazdu za pomocą GPS, system będzie automatycznie planował wymianę opon. Otworzy to możliwość stworzenia nowego rodzaju modeli biznesowych opartych na danych i zaowocuje wiarygodnymi informacjami zwrotnymi dla producenta na temat eksploatacji jego produktów. Klient będzie otrzymywał wszystkie wiadomości o potrzebie wymiany lub ewentualnego serwisowania opon za pośrednictwem aplikacji mobilnej. Warto dodać, że za zgodą klienta działania te będą organizowane i wykonywane automatycznie. Zdecydowanie ułatwi to planowanie budżetu w przedsiębiorstwach. Opisane rozwiązanie w niedalekiej przyszłości z powodzeniem wesprze floty składające się z **autonomicznych pojazdów**, a następnie prawdopodobnie będzie dostępne również dla klientów prywatnych.

Opony jako produkty, których zakup związany jest z przemyślaną decyzją (przeciętny klient będzie przecież eksploatować jeden komplet opon przez kilka sezonów), nieustannie są przedmiotem zestawień i rankingów (Auto Bild, 2024). Osiągnięcie statusu marki konkurencyjnej na rynku jest zadaniem wielowątkowym i trudnym (Chicu i in., 2020), którego bazą jest obserwacja trendów rynku i umiejętność szybkiego wprowadzania zmian (Brusoni, 2021). Mogą one dotyczyć modeli biznesowych, zwiększania precyzyjności stosowanego **oprzyrządowania maszynowego** (Guo i in., 2009), a także wprowadzania **innowacyjnych mieszanek gumowych** (Rucińska i in., 2022).

Jednym z najczęściej poruszanych współcześnie aspektów dotyczących rozwoju branży oponiarskiej jest **estymacja sił** występujących w oponie (Xu i in., 2013). Badania (Xu i in., 2021) koncentrują się na problemie estymacji kąta znoszenia opon, który odgrywa kluczową rolę w dynamice i sterowaniu pojazdu. Autorzy zaproponowali innowacyjną metodę łączącą technologię inteligentnej opony z algorytmami uczenia maszynowego. W tym celu zastosowano akcelerometry MEMS zamocowane wewnątrz opony, rejestrujące przyspieszenia w trzech kierunkach. Zgromadzone dane poddano analizie zarówno w dziedzinie czasu, jak i częstotliwości, a następnie wykorzystano do trenowania pięciu metod uczenia

maszynowego. Najważniejszym wynikiem pracy było wykazanie, że analiza w dziedzinie częstotliwości – szczególnie z użyciem sieci neuronowej opartej na algorytmie Rprop – pozwala na znacznie dokładniejszą estymację kąta znoszenia w porównaniu z metodami opartymi na analizie czasowej czy modelach fizycznych. Dokładność predykcji utrzymywała się na wysokim poziomie nawet dla kątów do 10° (Rysunek 5.1.), co wykracza poza możliwości tradycyjnych metod, które zazwyczaj zawodzą powyżej $4\text{--}5^\circ$. Co istotne, zaproponowane podejście okazało się stosunkowo odporne na zmiany prędkości jazdy i obciążenia pionowego opony, co zwiększa jego potencjał aplikacyjny w rzeczywistych warunkach eksploatacyjnych.




Rysunek 5.1. Szacowany kąt znoszenia względem zmierzonego kąta znoszenia w warunkach wymuszenia trójkątnego (opracowanie własne na podstawie Xu i in., 2021)

Nowatorski model kinematyczny opony skrętnej, przedstawiony w (Vo i in., 2017) pozwala badać moment Kingpina³ podczas manewrów przy niskich prędkościach i dużym kącie skrętu. W artykule podkreślono ograniczenia tradycyjnych modeli opon w precyzyjnej analizie dynamiki pojazdu w ekstremalnych warunkach skręcania, szczególnie w kontekście interakcji opony z układem kierowniczym. Proponowany model umożliwia dokładną ocenę momentu Kingpina i zachowania opony, co ma istotne znaczenie dla bezpieczeństwa i sterowności pojazdu.

Prace nad **modelowaniem opon** coraz częściej integrują interaktywne narzędzia oraz zaawansowane procedury przetwarzania danych, np. TRIP-ID (Farroni i in., 2018), aby sprostać wymaganiom precyzji i adaptacyjności w dynamicznych warunkach rzeczywistych (Farroni, 2016). W artykule (Arat i in., 2013) przedstawiono badania

³ Moment Kingpina – pojęcie z dynamiki pojazdów odnoszące się do momentu obrotowego działającego wokół osi Kingpina w zawieszeniu kół skrętnych. Chodzi o moment, który „próbuję skręcić” zwrotnicę lub koło na pionowej osi obrotu w układzie kierowniczym.

nad wykorzystaniem technologii **inteligentnych opon** (*ang. smart tire technology*) w celu optymalnej alokacji sił działających na opony pojazdu. Autorzy wychodzą z założenia, że precyzyjna znajomość parametrów kontaktu opony z nawierzchnią, uzyskana dzięki sensorom umieszczonym w strukturze opony, może znacząco poprawić skuteczność systemów sterowania pojazdem, w szczególności systemów rozdziału sił w pojazdach wielonapędowych (Boada i in., 2009). W opracowaniu (Bastiaan, 2018) (Rysunek 5.2.) zaprezentowano algorytmy sterowania wykorzystujące dane z inteligentnych opon do dynamicznego rozdzielania sił napędowych i hamujących, tak aby maksymalizować przyczepność i stabilność pojazdu. Wyniki symulacji wykazały, że zastosowanie tej technologii pozwala na istotną poprawę bezpieczeństwa oraz efektywności jazdy, zwłaszcza w warunkach zmiennej przyczepności. W porównaniu do tradycyjnych metod rozdziału sił, rozwiązanie oparte na ‘*smart tire technology*’ charakteryzuje się większą adaptacyjnością i możliwością reakcji w czasie rzeczywistym.



Rysunek 5.2. Analiza Metodą Elementów Skończonych opony przy obciążeniu pionowym; „Magnitude” to wielkość konturów przemieszczeń określonych przez oprogramowanie ABAQUS (Bastiaan, 2018)

Praca (Beauchamp i in., 2016b) koncentruje się na analizie zależności pomiędzy charakterystyką **śladów opon** (*ang. striations*) a generowanymi siłami opon, co stanowi zagadnienie o istotnym znaczeniu zarówno w rekonstrukcji wypadków drogowych, jak i w badaniach nad interakcją opony z nawierzchnią. Autorzy przeprowadzili eksperymenty z wykorzystaniem kontrolowanych manewrów pojazdu, podczas których rejestrowano zarówno powstające ślady na nawierzchni, jak i parametry sił działających na oponę. Wyniki wskazują, że regularność, gęstość i kierunek pozostawionych śladów są bezpośrednio powiązane z poziomem sił poprzecznych i wzdłużnych działających na oponę. Oznacza


to, że analiza wizualna i geometryczna śladów opon może dostarczać informacji o warunkach pracy opony i wielkości oddziałujących na nią obciążeń. Co istotne, badania dowiodły, iż ślady opon nie są jedynie artefaktem tarcia, lecz niosą ze sobą istotne dane diagnostyczne, które mogą być wykorzystywane w inżynierii bezpieczeństwa oraz sądownictwie technicznym. Wnioski autorów podkreślają, że dokładne modelowanie zależności między śladami opon a siłami wymaga dalszych badań, jednak uzyskane już wyniki stanowią podstawę do rozwijania narzędzi analitycznych wspomagających identyfikację dynamiki pojazdu na podstawie śladów pozostawionych na nawierzchni (Beauchamp i in., 2016a).

W artykule (Chołodowski i Dudziński, 2015) przedstawiono innowacyjną metodę eksperymentalnej **identyfikacji deformacji** opon pojazdów, koncentrując się na opracowaniu nowatorskiego przetwornika zdolnego do pomiaru trzech składowych deformacji opon. Autorzy wskazują na ograniczenia dotychczas stosowanych metod pomiaru, w których często brakuje pełnej charakterystyki deformacji w trzech wymiarach, co ogranicza dokładność analizy dynamicznej zachowania opony.

Badania wpływu deformacji opony na aerodynamikę pojazdów z odkrytymi kołami (Eder i in., 2020) obejmowały symulacje przepływu powietrza z uwzględnieniem odkształceń opony, co pozwoliło ocenić, w jaki sposób zmiany jej kształtu wpływają na **charakterystyki aerodynamiczne**. Autorzy wykazali, że deformacja opon istotnie modyfikuje strukturę przepływu powietrza wokół koła (Rysunek 5.3.), a tym samym ma znaczący wpływ na opór aerodynamiczny oraz stabilność pojazdu. Wnioski z pracy wskazują, że uwzględnianie deformacji opon w analizach aerodynamicznych jest kluczowe dla dokładnego przewidywania zachowania pojazdów wyścigowych i sportowych, gdzie wpływ aerodynamiki ma szczególne znaczenie.



Publikacja (Matsubara i in., 2022) przedstawiają system wizualizacji rozkładu odkształceń i pomiaru deformacji klocków bieżnika opon podczas szybkiego obracania się kół pojazdu. W pracy podkreślono ograniczenia tradycyjnych metod pomiarowych, które nie pozwalają na dokładne uchwycenie dynamicznych odkształceń bieżnika (Kan i in., 2020) przy dużych prędkościach obrotowych. Zaproponowany system umożliwia dokładną obserwację i analizę rozkładu odkształceń w czasie rzeczywistym, co pozwala lepiej zrozumieć interakcje opony z nawierzchnią w warunkach dynamicznych. Artykuł ten wypełnia lukę w badaniach nad dynamicznymi właściwościami bieżnika opony. Podobnie, praca (Angrick i in., 2014) oceniała wpływ temperatury rdzenia i powierzchni opony na jej charakterystyki boczne, koncentrując się na zmianach sił i momentów generowanych podczas skrętu kół. W pracy

podkreślono, że **temperatura opony** (Rysunek 5.4.) istotnie wpływa na przyczepność boczną, deformacje bieżnika oraz moment samonastawny.



Rysunek 5.3. Struktura przepływu wokół ścieżki kontaktu opony nieodkształconej (a) oraz odkształconej (b) przy pochyleniu opony o 4° (Eder i in., 2020)

Publikacje (Hsiao i Yang, 2016; Hu i in., 2017) oceniają interakcję opony z nawierzchnią poprzez opracowanie metod szacowania **współczynnika tarcia**. Wątek tarcia uzupełniają (Lu i in., 2022), zajmując się wyznaczaniem tego współczynnika dla nawierzchni. Artykuł (Luty, 2018) traktuje o analizie **wpływu masy pojazdu na drogę hamowania** z wykorzystaniem metod symulacyjnych. Badania obejmowały modelowanie dynamiczne pojazdu w różnych wariantach masy oraz symulowanie scenariuszy awaryjnego hamowania w celu oceny zmian długości drogi zatrzymania. Autor podkreśla, że wzrost masy pojazdu prowadzi do znaczącego wydłużenia drogi hamowania, co ma bezpośrednie konsekwencje dla bezpieczeństwa ruchu drogowego. Wnioski płynące z badań wskazują, że masa pojazdu jest jednym z kluczowych czynników determinujących skuteczność hamowania, a jej uwzględnienie jest niezbędne przy projektowaniu systemów hamulcowych oraz ocenie ryzyka w ruchu drogowym. Studium skuteczności hamowania obejmuje również ewaluację układów hamulcowego (Dobaj, 2022) oraz zawieszenia (Lukoševičius i in., 2021) pojazdu.

Charakterystyka	Tendencja	Wpływ
Sztywność w zakręcie		3-4% na każde 10[K]
Relaksacja		Brak wyraźnego wpływu
Maksymalny współczynnik tarcia		0-5% na każde 10[K]

Rysunek 5.4. Wyniki badań nad wpływem temperatury opony na jej charakterystyki boczne
(opracowanie własne na podstawie Angrick i in., 2014)

Kolejnym aspektem, który stanowi aktualny przedmiot badań jest **akustyka opony**. Autorzy (Cao i Bolton, 2015) przedstawili udoskonalony model sprzężonych trybów strukturalno-akustycznych opon, mający na celu dokładniejszą analizę drgań i emisji hałasu generowanego przez opony podczas jazdy. Autorzy skupili się na modelowaniu współzależności między deformacjami strukturalnymi a efektami akustycznymi, co pozwala na lepsze przewidywanie zachowania opony w warunkach rzeczywistych oraz projektowanie cichszych i bardziej komfortowych opon. Badania (Gautam i in., 2017) skupiały się natomiast na opracowaniu statystycznego modelu przewidującego hałas opon przy różnych prędkościach. Badania koncentrowały się na analizie danych eksperymentalnych dotyczących emisji hałasu toczenia, z uwzględnieniem wpływu prędkości pojazdu na poziom generowanego dźwięku. Okazało się, że model statystyczny pozwala na precyzyjne prognozowanie hałasu opon, co może wspierać projektowanie cichszych opon oraz polepszenie warunków komfortu akustycznego w pojazdach. W (Yoon i in., 2022) opracowano model predykcyjny hałasu dla danego wzoru bieżnika opon z wykorzystaniem konwolucyjnych sieci neuronowych oraz algorytmu RMSProp. Celem pracy była automatyczna analiza i prognozowanie emisji hałasu generowanego przez różne układy bieżnika, co pozwala na szybszą i bardziej precyzyjną ocenę akustycznych właściwości opon już na etapie projektowania. Autorzy wykazali, że podejście oparte na sztucznej inteligencji może skutecznie zastąpić tradycyjne, czasochłonne metody eksperymentalne. Publikacja (Zhu i in., 2023) również udowadnia kluczowy wpływ rzeźby bieżnika na emisję hałasu.

Opracowania (Kuric i in., 2021; Kuric i in., 2022) skupiają się na analizie możliwości **inspekcji defektów** opon z wykorzystaniem metod uczenia nienadzorowanego oraz głębokiego uczenia. Autorzy skupili się na zastosowaniu algorytmów sztucznej inteligencji do automatycznego wykrywania uszkodzeń strukturalnych, które mogą występować w trakcie produkcji lub eksploatacji opon. W pracy podkreślono potencjał technik głębokiego uczenia do przetwarzania obrazów i sygnałów pomiarowych, co pozwala na zwiększenie skuteczności i dokładności diagnostyki w porównaniu z tradycyjnymi metodami inspekcji. Wnioski z badań wskazują, że integracja metod sztucznej inteligencji w procesie kontroli jakości opon może znacząco poprawić bezpieczeństwo eksploatacyjne oraz efektywność produkcji, redukując ryzyko występowania defektów w gotowych wyrobach.


Realizowany jest również rozwój **metod pomiarowych**, czego przykładem jest praca (Lung i in., 2016), gdzie autorzy zaproponowali system do pomiaru głębokości bieżnika opon oparty na technologii laserowej i kamerze CMOS. System ten umożliwia bezkontaktową i precyzyjną ocenę zużycia opon. Zastosowano tu model liniowy do kalibracji i analizy danych pomiarowych. Podobnie w artykule (Mastrodicasa i in., 2021), autorzy skupili się na analizie hałasu i wibracji generowanych przez opony, szczególnie w kontekście pojazdów elektrycznych, gdzie brak silnika spalinowego sprawia, że hałas opon staje się dominującym czynnikiem. W badaniach zastosowano nienalogowe metody pomiarowe, takie jak Digital Image Correlation (DIC) oraz Laser Doppler Vibrometry (LDV), które pozwalają na uzyskanie pełnowymiarowych danych dotyczących zachowania opony w warunkach statycznych. Analiza obejmowała zarówno opony w stanie swobodnym, jak i poddane statycznemu obciążeniu. Uzyskano pełnowymiarowe mapy odkształceń i prędkości powierzchniowych opony oraz wyodrębniono charakterystyki modalne opony, tj. częstotliwości własne, współczynniki tłumienia oraz kształty modów. Te informacje mogą być wykorzystane do poprawy dokładności modeli opon, zarówno w kontekście aktualizacji modeli opartych na metodzie elementów skończonych (FE), jak i w opracowywaniu modeli opartych na funkcjach odpowiedzi (FRF).

Dzięki coraz powszechniejszemu zastosowaniu czujników **monitorowania ciśnienia** w oponach typu TPMS (*ang. Tire Pressure Monitoring System*), autorzy (Schwall i in., 2016) przeanalizowali dane czasowe ciśnienia w samochodach Tesla Model S, aby zrozumieć zmiany ciśnienia spowodowane przez różne czynniki, tj. przenikanie powietrza, powolne wycieki oraz wahania temperatury w cyklu jazdy i w skali sezonowej. Autorzy wskazali, że ciśnienie w oponach zmienia się w odpowiedzi na zmiany temperatury oraz na efekty przenikania powietrza przez materiał opony.

Nowatorskie badania prowadzi się również w kierunku uzyskania podobnego poziomu własności jak dla opon pneumatycznych przez **opony niepneumatyczne**. W pracy (Jackowski i in., 2023) dokonano porównawczej analizy małogabarytowych opon niepneumatycznych oraz opon pneumatycznych, skupiając się na takich parametrach jak sztywność radialna, histereza oraz wybrane cechy plamy kontaktu. Autorzy wskazali istotne różnice w charakterystyce pracy obu typów opon, podkreślając zalety konstrukcji niepneumatycznych w zakresie odporności na uszkodzenia i stabilności parametrów eksploatacyjnych, przy jednoczesnym zwróceniu uwagi na ograniczenia dotyczące właściwości dynamicznych i komfortu jazdy. Wnioski z pracy wskazują, że opony niepneumatyczne stanowią obiecującą alternatywę dla tradycyjnych opon pneumatycznych, szczególnie w zastosowaniach specjalistycznych, jednak ich charakterystyka wymaga dalszych badań i poprawy. Natomiast w artykule (Zhang i in., 2020) porównano statyczne i dynamiczne właściwości opony niepneumatycznej z elastyczną strukturą szprychową (Rysunek 5.5.). Badania obejmowały ocenę sztywności, zdolności tłumienia oraz parametrów dynamicznych w różnych warunkach obciążenia i prędkości. Autorzy wykazali, że elastyczne szprychy wpływają na poprawę komfortu i właściwości tłumiących opony, przy jednoczesnym zachowaniu jej odporności na przebicia i stabilności konstrukcyjnej. Wnioski z pracy wskazują, że opony niepneumatyczne z elastycznymi szprychami stanowią perspektywiczną alternatywę dla tradycyjnych opon pneumatycznych, szczególnie w zakresie zwiększonej niezawodności i odporności na awarie.

Najczęściej stosowane współcześnie metody eksploracji tematyki związanej z rozwojem przemysłu oponiarskiego opierają się na uczeniu maszynowym. Świadczy o tym chociażby częstotliwość wyboru tych metod w publikacjach przytoczonych w niniejszym rozdziale. Dodatkowo, metody te znajdują zastosowanie w systemach pompowania opon (Choudhury i in., 2017) i przewidywaniu ich żywotności (Zhu i in., 2021).

W analogii do niniejszej dysertacji, (Tamborski i in., 2023) analizuje wpływ sztucznej inteligencji na **procesy kontroli jakości** w przemyśle oponiarskim, ze szczególnym uwzględnieniem badań naukowych, rozwoju technologii oraz zastosowań praktycznych w produkcji i eksploatacji opon. Analizie poddano metody takie jak cyfrowa szerografia wspomagana uczeniem głębokim, inkrementalne modele YOLO do detekcji defektów, segmentacja obrazów głębi oraz wykorzystanie cyfrowych bliźniaków w procesach projektowania i testowania opon.



Rysunek 5.5. Rozkład naprężeń i deformacji dla: a) opony pneumatycznej napelnianej powietrzem, b) opony niepneumatycznej z płytą szprychową, c) opony niepneumatycznej o strukturze plastra miodu oraz d) opony niepneumatycznej o strukturze kratowej, przy obciążeniu nominalnym 3000[N] (Zhang i in., 2020)

Badania wskazują, że zastosowanie AI znacząco zwiększa skuteczność i precyzję wykrywania defektów, redukuje czas inspekcji oraz umożliwia wczesną identyfikację wad produkcyjnych i eksploatacyjnych. Rozwiązania oparte na sztucznej inteligencji mogą wspierać także predykcyjne utrzymanie opon oraz rozwój metod symulacyjnych w procesie projektowania. Przeprowadzony przegląd literatury sugeruje zatem możliwość zastosowania metod uczenia maszynowego do predykcji stożkowatości na bazie pomiarów przeprowadzanych podczas procesu konfekcji opon radialnych.

6. Modele uczenia maszynowego

Sztuczna inteligencja AI (*ang. artificial intelligence*) to dział informatyki i inżynierii zajmujący się tworzeniem systemów (sprzętowych lub programowych), które potrafią wykonywać zadania wymagające inteligencji – takie jak rozumowanie, uczenie się, interpretowanie danych ze środowiska, podejmowanie decyzji czy dostosowywanie się do zmian. Systemy te przy wykorzystaniu algorytmów (np. uczenia maszynowego, sieci neuronowych, logiki symbolicznej) mogą samodzielnie usprawniać swoje działanie, przewidywać zachowania czy reagować na nowe sytuacje (European Commission, 2019).


Uczenie maszynowe ML (*ang. machine learning*) to dział sztucznej inteligencji zajmujący się tworzeniem modeli i algorytmów, które na podstawie danych potrafią samodzielnie uczyć się, wykrywać wzorce i korelacje oraz poprawiać swoje działanie bez potrzeby wyraźnego instruktażu (“jawnego programowania”) każdego kroku. Modele te są trenowane na danych historycznych, a następnie używane do przewidywania, klasyfikowania lub podejmowania decyzji w oparciu o nowe dane (Rogalski M., 2025).

6.1 Rodzaje uczenia maszynowego

Modele uczenia maszynowego umożliwiają eksplorację wielowymiarowych i obszernych zbiorów danych w celu identyfikacji ukrytych struktur oraz zależności. Istotnym aspektem analizy danych jest zdolność do transformacji danych surowych w informacje użyteczne, które mogą stanowić podstawę do podejmowania decyzji wspierających procesy biznesowe w organizacjach (Rosienkiewicz, 2021; Antunes Rodrigues i in., 2022). Dobór oraz implementacja odpowiedniego modelu uczenia maszynowego, zdolnego do przekształcenia danych wejściowych w wartościową wiedzę, zależy od szeregu czynników – w głównej mierze charakterystyki problemu analitycznego oraz jakości i rodzaju dostępnych danych.

Na Rysunku 6.1. zaprezentowano podstawowy podział rodzajów uczenia maszynowego w zależności od stopnia nadzoru wykorzystywanego podczas trenowania, wraz z przykładami typowych metod stosowanych w poszczególnych kategoriach modeli oraz reprezentatywnymi problemami rozwiązywanymi z ich zastosowaniem. Wyróżnia się m.in. następujące rodzaje uczenia maszynowego (Burkov, 2019):

- 1) Nadzorowane (*ang. supervised learning*).
- 2) Nienadzorowane (*ang. unsupervised learning*).
- 3) Przez wzmacnianie (*ang. reinforced learning*).



Rysunek 6.1. Rodzaje uczenia maszynowego oraz ich zastosowanie (opracowanie własne na podstawie Burkov, 2019; Miśtak, 2025)

Należy jednak zauważyć, że wiele modeli ma charakter uniwersalny i może być wykorzystywana zarówno w zadaniach klasyfikacyjnych, jak i regresyjnych. Dobór adekwatnej metody uczenia maszynowego warunkowany jest nie tylko ilościowymi i jakościowymi cechami dostępnych zbiorów danych, lecz również charakterystyką problemu badawczego, który podlega analizie. Istotne znaczenie mają m.in. klasa problemu (klasyfikacja, regresja), rodzaj danych (np. dane numeryczne, tekstowe, szereg czasowy), obecność szumu informacyjnego, a także wymagania dotyczące interpretowalności modelu, jego wydajności obliczeniowej oraz możliwości generalizacji wyników. W konsekwencji wybór konkretnej metody ML powinien być poprzedzony wnikliwą analizą kontekstu zastosowania oraz specyfiki danych wejściowych.

6.1.1 Uczenie nadzorowane

Uczenie nadzorowane stanowi najbardziej rozwiniętą i powszechnie stosowaną gałąź uczenia maszynowego, której istotą jest identyfikacja wzorców na podstawie zbiorów danych zawierających znane, uprzednio oznaczone wyniki. Proces ten polega na budowaniu modeli poprzez analizę relacji pomiędzy zestawem zmiennych niezależnych (atrybutów, zmiennych objaśniających, cech – *ang. features*), oznaczanych jako X , a odpowiadającym im zbiorem wartości docelowych (zmiennych zależnych, objaśnianych), oznaczanych jako Y (Theobald, 2017). Algorytm uczenia nadzorowanego analizuje dane treningowe w celu identyfikacji statystycznych zależności pomiędzy cechami a wynikami. W wyniku tego procesu generowany jest model, który umożliwia generowanie wyników dla nieznanych danych wejściowych, na podstawie wcześniej wyuczonych wzorców. Trafność modelu oceniana jest za pomocą odpowiednio dobranej funkcji straty (*ang. loss function*), która wyznacza różnicę pomiędzy wartościami przewidywanymi a rzeczywistymi. Proces trenowania modelu polega na iteracyjnym minimalizowaniu wartości tej funkcji, aż do osiągnięcia satysfakcjonującego poziomu dokładności (Theobald, 2017). Modele oparte na uczeniu nadzorowanym znajdują zastosowanie w dwóch podstawowych klasach problemów (Burkov, 2019):

- 1) Regresji – polegającej na przewidywaniu zmiennych ciągłych, które mogą przyjmować dowolne wartości liczbowe w określonym zakresie.
- 2) Klasyfikacji – polegającej na przypisywaniu danych wejściowych do jednej z kategorii dyskretnych ze skończonego zbioru.

Modele regresyjne znajdują swoje zastosowanie między innymi w analizie informacji produkcyjnych (Biyeme i in., 2023; Dharwadkar i in., 2022; Fertsch M., 2020), przewidywaniu

rezultatów zastosowania nowych rozwiązań w rolnictwie (Gao i in., 2023), przewidywaniu zapotrzebowania produktów i dóbr (Kittichotsatsawat i in., 2022; Cieślik i Metelska, 2017), estymacji cyklu życia produktu (Viana i in., 2023; Su i in., 2021), czy predykcji terminu przeglądów technicznych (Owczarek i in., 2022; Kim, 2023). Metody, które są stosowane do rozwiązywania problemów regresji to m.in.:

- 1) Regresja liniowa - stanowi jedną z najczęściej stosowanych metod predykcyjnych w analizie statystycznej oraz uczeniu maszynowym. Jej podstawy teoretyczne zostały sformułowane przez J. L. Lagrange'a oraz C. F. Gauss'a (Seal, 1967). Metoda ta opiera się na modelowaniu zależności liniowej pomiędzy zmienną objaśnianą (wyjściową) Y, a jedną lub wieloma zmiennymi objaśniającymi (wejściowymi) X. W przypadku, gdy model uwzględnia tylko jedną zmienną niezależną mówi się o prostej regresji liniowej. Ilustrację dopasowania takiego modelu przedstawiono na Rysunku 6.2. Natomiast w sytuacji, gdy w analizie bierze udział większa liczba zmiennych wejściowych, mamy do czynienia z regresją liniową wielokrotną (wielowymiarową, zwaną również wieloraką) (Brownlee, 2016; Szaleniec, 2008). Model prostej regresji liniowej można zapisać w postaci Równania 6.1:

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n + \varepsilon \quad (6.1)$$

gdzie:

Y – zmienna zależna;


$X_1, X_2, \dots, X_n$ – zmienne niezależne;

b_0 – wyraz wolny (punkt przecięcia z osią Y);

$b_1, \dots, b_n$ – współczynniki regresji (wagi zmiennych);

ε – składnik losowy (reszta, błąd).

Jedną z najczęściej stosowanych metod estymacji parametrów modelu regresji liniowej jest metoda najmniejszych kwadratów. Polega ona na minimalizacji sumy kwadratów odchyleń obserwowanych wartości zmiennej zależnej od wartości przewidywanych przez model regresyjny. Innymi słowy, estymacja parametrów odbywa się poprzez dopasowanie prostej regresji w taki sposób, aby łączna kwadratowa odległość punktów empirycznych od tej prostej była możliwie najmniejsza.



Rysunek 6.2. Dopasowanie modelu za pomocą prostej regresji liniowej (Skoneczny, 2025)

Regresja liniowa charakteryzuje się prostotą zarówno pod względem koncepcyjnym, jak i implementacyjnym. Czyni ją to jednym z najbardziej przystępnych algorytmów w analizie danych. Ponadto, cechuje się relatywnie krótkim czasem obliczeń w porównaniu z bardziej zaawansowanymi metodami predykcyjnymi. Niemniej jednak, model ten wykazuje wysoką wrażliwość na obserwacje odstające (*ang. outliers*), które mogą znacząco zaburzyć wyniki estymacji parametrów i tym samym obniżyć trafność predykcji.

- 2) Regresja wielomianowa – metoda do modelowania nieliniowych zależności pomiędzy zmienną zależną a jedną lub wieloma zmiennymi niezależnymi. Polega ona na aproksymacji danych empirycznych za pomocą funkcji wielomianowej określonego stopnia, co umożliwia uchwycenie bardziej złożonych, krzywoliniowych relacji (Rysunek 6.3.) niż w przypadku klasycznej regresji liniowej (Filipow i in., 2023). Ogólna postać modelu regresji wielomianowej stopnia n wyraża się Równaniem 6.2.:


$$Y = b_0 + b_1X + b_2X^2 + b_3X^3 + \dots + b_nX^n \quad (6.2)$$

gdzie:

Y – funkcja wielomianowa;

X – zmienna wejściowa;

b – szukane współczynniki regresji.



**Rysunek 6.3. Dopasowanie modelu za pomocą prostej regresji wielomianowej
(Dopasowanie krzywej w Pythonie, 2025)**

Model ten może być również rozszerzony na przypadki wielowymiarowe, poprzez uwzględnienie potęg i interakcji wielu zmiennych wejściowych. Regresja wielomianowa, dzięki swojej elastyczności, znajduje zastosowanie w sytuacjach, w których dane nie spełniają założeń liniowości, jednak jej stosowanie wymaga ostrożności ze względu na możliwość nadmiernego dopasowania modelu do danych uczących (*ang. overfitting*), zwłaszcza przy wysokich stopniach wielomianu.


Nawiązując do podziału zaproponowanego na Rysunku 6.1, do metod pozwalających rozwiązywać zarówno problemy regresji, jak i klasyfikacji należą m.in.:

- 1) Drzewa decyzyjne – nazywane również CART (*ang. classification and regression trees*) to jedna z fundamentalnych metod stosowanych w analizie danych, zarówno w kontekście problemów klasyfikacyjnych, jak i regresyjnych (Breiman, 1984). Drzewa decyzyjne to struktury grafowe, których architektura umożliwia modelowanie zbioru reguł decyzyjnych, wykorzystywanych do prognozowania wartości zmiennej wyjściowej na podstawie zestawu cech wejściowych. Strukturę drzewa decyzyjnego tworzą następujące elementy (Bujak, 2008; Hastie i in., 2009):
 - a) Korzeń – reprezentuje punkt początkowy konstrukcji drzewa i obejmuje cały zbiór danych treningowych.
 - b) Węzły wewnętrzne – odpowiadają za dokonywanie podziałów zbioru danych na podstawie wartości wybranych atrybutów. Każdy węzeł zawiera jedną cechę lub ich kombinację, na podstawie której wykonywany jest podział obserwacji

na podzbiory. Węzły są odzwierciedleniem reguł decyzyjnych, wskazujących które obserwacje mają zostać przekierowane do kolejnych części drzewa.

- c) Liście (węzły końcowe) – zawierają finalne decyzje klasyfikacyjne lub predykcyjne. Każdy liść reprezentuje wynik analizy – przypisaną klasę (w przypadku klasyfikacji) lub wartość liczbową (dla regresji).

Mechanizm działania drzewa decyzyjnego polega na iteracyjnym dzieleniu przestrzeni danych na mniejsze, bardziej jednorodne podzbiory przy użyciu wybranych atrybutów. Proces ten trwa do momentu spełnienia określonego „warunku stopu”, którym może być osiągnięcie maksymalnej dozwolonej głębokości drzewa lub brak dalszego przyrostu informacyjnego, czyli sytuacji gdy dalszy podział nie przynosi znaczącej poprawy w dopasowaniu modelu do danych. Podobnie jak w przypadku regresji wielomianowej, należy podchodzić z ostrożnością do zbytniego dopasowania modelu do danych uczących (*ang. overfitting*), tak jak zostało to przedstawione na Rysunku 6.4. dla drzewa o parametrze `max_depth = 5`.



Rysunek 6.4. Odzwierciedlenie wartości przez model za pomocą drzew decyzyjnych (Decision Tree Regression , 2025)

W celu zwiększenia efektywności modeli opartych na drzewach decyzyjnych, możliwe jest zastosowanie metod wzmocnienia, tj.:


- a) Las losowy (*ang. Random Forest*) – metoda polegająca na budowaniu wielu drzew decyzyjnych, z których każde trenowane jest na losowo wybranym fragmencie danych uczących. Ostateczna decyzja klasyfikacyjna lub predykcyjna podejmowana

jest na podstawie głosu większości spośród wszystkich drzew. Metoda ta pozwala zredukować ryzyko nadmiernego dopasowania modelu (Cutler, 2011).

- b) Wzmocnienie gradientowe (*ang. gradient boosting*) – metoda uczenia zespołowego, w której drzewa decyzyjne budowane są w sposób sekwencyjny. Każde kolejne drzewo koncentruje się na minimalizacji błędów popełnionych przez poprzednie modele, wykorzystując do tego informacje o kierunku największego spadku funkcji straty, czyli gradient (Hastie i in., 2009). Do najbardziej znanych i szeroko stosowanych modeli opartych na wzmocnieniu gradientowym należą m.in.: XGBoost (*Extreme Gradient Boosting*) (Chen i Guestrin 2016), LightGBM (*Light Gradient Boosting Machine*) (Microsoft Corporation, 2023) oraz CatBoost, które charakteryzują się wysoką wydajnością obliczeniową, odpornością na przeuczenie oraz zdolnością do pracy z dużymi i zróżnicowanymi zbiorami danych.

- 2) Sztuczne sieci neuronowe – podstawową jednostkę obliczeniową stanowi tutaj sztuczny neuron, często nazywany perceptronem. Jest to uproszczony model matematyczny inspirowany funkcjonowaniem neuronu biologicznego (Mamczur, 2025). Perceptron przetwarza dane wejściowe poprzez obliczenie sumy ważonej sygnałów pochodzących od neuronów warstwy poprzedniej, a następnie przekazuje wynik przekształcony za pomocą funkcji aktywacji (Ramchoun, 2016). W klasycznym perceptronie jednowarstwowym wynik ten ma postać wartości binarnej, jednak w nowocześniejszych sieciach wartość wyjściowa może być ciągła i zależna od użytej funkcji aktywacji. Na Rysunku 6.5. przedstawiono matematyczny model neuronu nawiązujący do jego biologicznego odpowiednika – dendryty symbolizują dane wejściowe, ciało komórki to funkcja sumująca i aktywacji, natomiast akson jest odzwierciedleniem danej wyjściowej. Każde z wejść (x_i) ma przypisaną wagę (w_i), która jest wyznaczana na podstawie istotności danego wejścia w porównaniu do innych danych wejściowych. Dodatkowo uwzględniany jest współczynnik b , zwany odchyleniem (*ang. bias*). W węźle realizowana jest nieliniowa funkcja f (ważona suma wejść) nazywana funkcją aktywacji. Zgodnie z przedstawionym opisem wyjście neuronu obliczane jest zgodnie z Równaniem 6.3 (Ducic i in., 2020):

$$Y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (6.3)$$




Rysunek 6.5. Model matematyczny neuronu (Zajac, 2025)

Sieć neuronowa zbudowana jest z minimum trzech warstw funkcjonalnych (Theobald, 2017):

- Warstwa wejściowa (*ang. input layer*) – odpowiedzialna za odbiór danych wejściowych i ich przekazanie do kolejnych warstw przetwarzających. Sama warstwa nie realizuje operacji obliczeniowych, lecz może pełnić funkcje wstępnego przekształcenia danych, takie jak normalizacja lub skalowanie.
- Warstwy ukryte (*ang. hidden layers*) – stanowią główny komponent obliczeniowy sieci neuronowej. Każda warstwa składa się z zestawu neuronów, które wykonują operację sumy ważonej sygnałów wejściowych, przekształcają ją za pomocą nieliniowej funkcji aktywacji, a następnie przekazują wynik do kolejnej warstwy. W zależności od głębokości sieci, liczba warstw ukrytych może się różnić. Sterowanie liczbą tych warstw umożliwia modelowi hierarchiczne wydobywanie coraz bardziej złożonych reprezentacji danych wejściowych.
- Warstwa wyjściowa (*ang. output layer*) – generuje końcowy rezultat działania sieci neuronowej. Liczba neuronów w tej warstwie oraz zastosowana funkcja aktywacji są uzależnione od typu rozwiązywanego problemu (np. klasyfikacja, regresja).

Ilustrując powyższy opis, na Rysunku 6.6. przedstawiono uproszczony schemat sieci neuronowej uwzględniający warstwy wejściową i wyjściową oraz warstwy ukryte.




Rysunek 6.6. Uproszczony schemat sieci neuronowej (Magnuski, 2024)

Najpopularniejsze funkcje aktywacji (Mamczur, 2024) przedstawiono na Rysunku 6.7.:

- Funkcja sigmoidalna – zwraca wartości w przedziale 0 i 1.
- Tangens hiperboliczny – zwraca wartości w przedziale -1 i 1.
- ReLU - zwraca wartości z przedziału 0 i 1.


Sigmoid

$$\sigma(x) = \frac{1}{1+e^{-x}}$$




tanh

$$\tanh(x)$$



ReLU

$$\max(0, x)$$




Rysunek 6.7. Najczęściej stosowane funkcje aktywacji (opracowanie własne na podstawie Mamczur, 2024)

Sztuczne sieci neuronowe znajdują zastosowanie w szerokim spektrum zagadnień z zakresu uczenia maszynowego, obejmując zarówno problemy regresji – polegające na estymacji wartości liczbowych na podstawie danych wejściowych – jak i klasyfikacji, gdzie celem jest przypisanie obserwacji do jednej z określonych kategorii. Jednym z najbardziej podstawowych, a jednocześnie uniwersalnych modeli sieci neuronowych jest perceptron wielowarstwowy MLP (*ang. multilayer perceptron*), zaliczany do grupy sieci jednokierunkowych. Składa się on z co najmniej jednej warstwy ukrytej, co pozwala mu modelować zależności nieliniowe pomiędzy danymi wejściowymi a wyjściem modelu. Dzięki swojej strukturze oraz wykorzystaniu nieliniowych funkcji aktywacji, perceptron wielowarstwowy może aproksymować dowolną funkcję ciągłą (Mohammadi i in., 2018).

- 3) Algorytm SVM (*ang. support vector machines*) – jedna z fundamentalnych metod uczenia maszynowego wykorzystywana zarówno w problemach regresyjnych, jak i klasyfikacyjnych, jednak jego zastosowanie w kontekście klasyfikacji jest bardziej rozpowszechnione. SVM to metoda klasyfikacji binarnej, której głównym celem jest wyznaczenie optymalnej hiperpłaszczyzny separującej dwie klasy obserwacji w przestrzeni cech, zakładając, że dane są liniowo separowalne (Halev-Shwartz i Ben-David, 2014). Podstawowa koncepcja działania tego algorytmu opiera się na maksymalizacji marginesu, tj. odległości między hiperpłaszczyzną a najbliższymi punktami danych obu klas. Punkty znajdujące się najbliżej wyznaczonej hiperpłaszczyzny i mające bezpośredni wpływ na jej położenie, określane są mianem wektorów nośnych (*ang. support vectors*) – to właśnie od nich pochodzi nazwa algorytmu (Grus, 2018). Działanie algorytmu SVM składa się z kilku kluczowych etapów, z których każdy ma istotne znaczenie dla skuteczności procesu klasyfikacji. W pierwszej fazie dane wejściowe poddawane są transformacji w taki sposób, aby możliwe było ich przedstawienie w postaci wektorów w przestrzeni wielowymiarowej. Umożliwia to zastosowanie geometrycznych metod analizy danych. Kolejnym etapem jest wyznaczenie hiperpłaszczyzny separującej dane należące do różnych klas. W tym celu najczęściej stosuje się dwie strategie: metodę największego marginesu (*ang. maximal margin*), która zakłada istnienie idealnej separacji liniowej, oraz metodę miękkiego marginesu (*ang. soft margin*) pozwalającą na pewien stopień błędu klasyfikacyjnego w celu uzyskania lepszej generalizacji modelu. W sytuacji, gdy dane nie są liniowo separowalne, SVM wykorzystuje przekształcenia przestrzeni

cech za pomocą funkcji jądrowych (*ang. kernel functions*). Funkcje te umożliwiają rzutowanie danych do przestrzeni o wyższej liczbie wymiarów, w której możliwe staje się liniowe oddzielenie klas. Po dokonaniu transformacji danych, model przystępuje do procesu optymalizacji. Celem tego etapu jest wyznaczenie położenia hiperpłaszczyzny maksymalizującej margines między klasami oraz identyfikacja wektorów nośnych (Rysunek 6.8.), które determinują jej orientację w przestrzeni cech (Bishop, 2006). Po wyznaczeniu hiperpłaszczyzny decyzyjnej możliwe jest klasyfikowanie nowych obserwacji. SVM ocenia położenie obserwacji względem hiperpłaszczyzny i przypisuje jej odpowiednią etykietę klasową. Dzięki tej właściwości model zapewnia wysoką skuteczność klasyfikacji, szczególnie w przypadku danych liniowo separowalnych. Z uwagi na swoją zasadę działania oraz efektywność obliczeniową, SVM znajduje również zastosowanie w analizie danych o charakterze liniowym (Hastie i in., 2009).



Rysunek 6.8. Ilustracja idei wektorów nośnych (Metoda wektorów nośnych, 2025)

- 4) Algorytm K-najbliższych sąsiadów KNN (*ang. K-nearest Neighbours*) – model stosowany zarówno w zadaniach klasyfikacyjnych, jak i regresyjnych. Jego działanie opiera się na założeniu, że obiekty znajdujące się w bliskim sąsiedztwie w przestrzeni cech wykazują tendencję do posiadania podobnych wartości cechy wyjściowej, co oznacza, że obiekty podobne do siebie mają zwykle tę samą etykietę (w przypadku klasyfikacji) lub zbliżoną wartość numeryczną (w przypadku regresji). W fazie treningowej metoda KNN nie dokonuje bezpośredniego modelowania danych – zamiast tego przechowuje cały zbiór treningowy jako referencyjny punkt odniesienia. W fazie prognozowania, dla każdej nowej obserwacji obliczana jest odległość pomiędzy punktem wejściowym a wszystkimi przykładami w zbiorze uczącym. Wykorzystywana jest do tego wybrana metryka odległości (Gokte, 2025), do których należą m.in:

- a) Odległość euklidesowa.
- b) Odległość Manhattan.
- c) Odległość Minkowskiego.

Na podstawie wybranej metryki identyfikowanych jest K najbliższych sąsiadów punktu wejściowego. W przypadku problemów klasyfikacyjnych, model przypisuje nowemu punktowi tę etykietę klasy, która dominuje wśród jego K sąsiadów, zgodnie z zasadą głosowania większościowego (*ang. majority voting*) (Srivastava, 2025). Natomiast w kontekście regresji, przewidywana wartość obliczana jest jako średnia (lub ważona średnia) wartości cech docelowych najbliższych sąsiadów (Rysunek 6.9.).



Rysunek 6.9. Schematyczne przedstawienie zasady działania algorytmu K-najbliższych sąsiadów
(opracowanie własne na podstawie Bukowski, 2025)

Model KNN cechuje się wysoką intuicyjnością i prostotą implementacyjną, co przyczynia się do jego szerokiego zastosowania w różnych dziedzinach analityki danych. Warto jednak zauważyć, że jego skuteczność i efektywność są silnie uzależnione od doboru liczby sąsiadów (K) oraz od wybranej metryki odległości. Nieodpowiednia konfiguracja tych parametrów może prowadzić do obniżenia zdolności predykcji / klasyfikacji, dlatego też w praktyce niezbędna jest ich optymalizacja (Srivastava, 2025).

Modele klasyfikacyjne natomiast, znajdują szerokie zastosowanie w przewidywaniu przynależności obiektów do określonych klas, kategorii lub grup. Wśród modeli stosowanych wyłącznie do rozwiązywania problemów klasyfikacyjnych wyróżnia się m.in. naiwny klasyfikator bayesowski NBC (*ang. naive Bayes classifier*). Znajduje on zastosowanie np. w klasyfikacji tekstów i filtrowaniu spamu. Opiera się na twierdzeniu Bayesa, które umożliwia wyznaczenie prawdopodobieństwa przynależności danej obserwacji

do określonej klasy na podstawie znanych cech. Kluczowym założeniem modelu jest niezależność warunkowa cech, oznaczająca, że występowanie jednej cechy nie wpływa na występowanie pozostałych. Pomimo, że w rzeczywistych danych założenie to rzadko jest w pełni spełnione, znacząco upraszcza ono model matematyczny i proces estymacji prawdopodobieństw. Z uwagi właśnie na tę właściwość, klasyfikator określany jest mianem „naiwnego”. Dzięki swojej prostocie obliczeniowej, łatwości implementacji oraz dobrej skuteczności wykorzystywany jest tam, gdzie interpretowalność oraz szybkość działania są istotnymi kryteriami (Hastie i in., 2009).

6.1.2 Uczenie nienadzorowane

Uczenie nienadzorowane stanowi podejście w uczeniu maszynowym, w którym modele trenowane są na danych nieoznakowanych, tj. pozbawionych etykiet lub znanych wartości wyjściowych. Celem tego typu uczenia jest wykrywanie ukrytych struktur, zależności lub regularności w danych bez nadzoru związanego z oczekiwanym wynikiem (Miśtak, 2025). W ramach uczenia nienadzorowanego wyróżnia się dwie podstawowe klasy problemów (Guide to Unsupervised Machine Learning: 7 Real Life Examples, 2025):


- 1) Analiza skupień (klasteryzacja) – polega na grupowaniu obiektów na podstawie stopnia ich podobieństwa, w celu wyodrębnienia wzorców oraz struktury wewnętrznej danych. Modele klasteryzujące mogą również służyć do wykrywania anomalii, czyli obserwacji odstających od pozostałych, które nie należą do żadnej z utworzonych grup (Sawka, 2020). Klasteryzacja danych to segmentacja obserwacji w homogeniczne grupy za pomocą metod takich jak *K-Means*, *DBSCAN* czy *Hierarchical Clustering*. Metody te są wykorzystywane np. w poszukiwaniu tendencji rynkowych, analizie zachowań użytkowników czy eksploracji sieci społecznych.
- 2) Redukcja wymiarowości – umożliwia przekształcenie danych (uproszczenie zbiorów danych) do przestrzeni o mniejszej liczbie zmiennych przy jednoczesnym zachowaniu istotnych informacji. Analiza głównych składowych PCA (*ang. principal component analysis*) jest stosowana do redukcji wymiarowości danych poprzez identyfikację kierunków największej wariancji oraz eliminację cech o niskiej wartości informacyjnej. Metody takie jak PCA czy jądrowa analiza głównych składowych (Kernel PCA) są szczególnie przydatne w kontekście wysokowymiarowych zbiorów danych, np. w bioinformatyce czy przetwarzaniu obrazów.

6.1.3 Uczenie przez wzmacnianie

Uczenie przez wzmacnianie to jedna z fundamentalnych metod uczenia maszynowego, w której agent (model decyzyjny) uczy się podejmowania sekwencji działań w dynamicznym, interaktywnym środowisku na podstawie sygnałów zwrotnych w postaci nagród i kar. Celem agenta jest wykształcenie strategii (polityki) postępowania, która maksymalizuje skumulowaną wartość oczekiwanych nagród w dłuższym horyzoncie czasowym. Podobnie jak w przypadku uczenia nadzorowanego, uczenie przez wzmacnianie zakłada istnienie funkcji odwzorowującej dane wejściowe na pożądaną odpowiedź. Różnica polega jednak na charakterze informacji zwrotnej: w uczeniu nadzorowanym agent otrzymuje jawny, poprawny zestaw wyjść dla danych wejściowych, natomiast w uczeniu przez wzmacnianie informacja zwrotna ma postać funkcji nagrody, wskazującej czy podjęte działanie było korzystne z punktu widzenia głównego celu. Uczenie przez wzmacnianie opiera się na kilku kluczowych pojęciach (Sinha, 2025):

- 1) Agent – model uczący się, który podejmuje decyzje i wpływa na środowisko.
- 2) Środowisko – zewnętrzny system (rzeczywisty lub symulowany), z którym agent wchodzi w interakcję.
- 3) Nagroda / kara – informacja zwrotna ze środowiska, oceniająca jakość podjętej decyzji.
- 4) Polityka – funkcja decyzyjna mapująca stany środowiska na działania.
- 5) Wartość – oczekiwana skumulowana nagroda uzyskana z danego stanu przy zastosowaniu danej polityki.

W odróżnieniu od uczenia nienadzorowanego, którego celem jest identyfikacja struktur, podobieństw i różnic w danych bez jawnych etykiet, celem uczenia przez wzmacnianie jest opracowanie takiej sekwencji decyzji (w tym przypadku polityki), która maksymalizuje długoterminową korzyść agenta. Agent podejmuje decyzje w środowisku, obserwuje ich konsekwencje w postaci nagród bądź kar i iteracyjnie dostosowuje swoje działania, eksplorując przestrzeń strategii oraz ucząc się na podstawie zgromadzonych doświadczeń (Rysunek 6.10.). Dzięki swojej elastyczności i zdolności do adaptacji w dynamicznych warunkach, uczenie przez wzmacnianie znajduje szerokie zastosowanie w praktyce, m.in. w robotyce, grach komputerowych, finansach oraz w optymalizacji procesów technologicznych i decyzyjnych (Sinha, 2025).



Rysunek 6.10. Pętla informacji zwrotnej „akcja-nagroda” modelu uczenia przez wzmocnienie
(opracowanie własne na podstawie Lorenzi, 2025)

6.2 Cykl życia modelu uczenia maszynowego

Cykl życia modelu uczenia maszynowego obejmuje zazwyczaj szereg kolejnych etapów, których realizacja stanowi warunek niezbędny do uzyskania poprawnego, wiarygodnego oraz wartościowego rezultatu:

- 1) **Zdefiniowanie problemu** – stanowi fundamentalny etap procesu projektowania modelu uczenia maszynowego, który determinuje zarówno wybór metod analizy, jak i kierunek dalszych działań. Na tym etapie konieczne jest precyzyjne określenie celu modelowania – czy problem ma charakter regresyjny (predykcja wartości liczbowych), czy też klasyfikacyjny (przypisanie obserwacji do jednej z kategorii). Proces ten wymaga również analizy kontekstu dziedzinowego, w którym model będzie wykorzystywany. Należy uwzględnić ograniczenia systemowe, wymagania związane z zastosowaniem modelu oraz potencjalne ryzyka spowodowane błędną predykcją / sklasyfikowaniem. Kluczowe jest zidentyfikowanie zmiennej objaśnianej oraz określenie dostępnych danych wejściowych, a także ewentualnych czynników zakłócających. Niedostateczna lub błędna definicja problemu może skutkować nieprecyzyjnym doбором modeli, niewłaściwą konstrukcją zbioru danych, czyli w konsekwencji ograniczoną użytecznością końcowego modelu.
- 2) **Gromadzenie danych** – w tym kroku istotne jest nie tylko zgromadzenie wystarczającej liczby obserwacji, lecz również zapewnienie, że dane pochodzą z wiarygodnych i spójnych źródeł. Jakość, kompletność oraz reprezentatywność

pozyskanych danych w sposób bezpośredni wpływają na zdolność modelu do uogólniania oraz jego użyteczność w zastosowaniach praktycznych. Dane powinny być reprezentatywne względem populacji docelowej i obejmować pełne spektrum zmienności zjawiska, którego dotyczy modelowanie.

- 3) **Przygotowanie i eksploracyjna analiza danych EDA (*ang. exploratory data analysis*)** – proces przygotowania danych, określany jako wstępne przetwarzanie danych (*ang. data preprocessing*) stanowiący niezbędny etap projektowania systemów uczących się. Obejmuje on szereg działań ukierunkowanych na dostosowanie surowych danych do wymagań modelu uczenia maszynowego (Al-jabery Khalid, 2020), co zostało zobrazowane na Rysunku 6.11. Do podstawowych działań zalicza się m.in.:
- a) Usuwanie duplikatów – polega na eliminacji powtarzających się rekordów, które mogą prowadzić do przewartościowania określonych obserwacji oraz zaburzać rozkłady statystyczne cech.
 - b) Uzupełnianie brakujących wartości – braki danych można usuwać (np. poprzez eliminację rekordów lub cech zawierających puste pola) bądź imputować, zastępując brakujące obserwacje wartością średnią, medianą, dominantą lub estymatą pochodzącą z modelu.
 - c) Transformacja danych nienumerycznych – dane tekstowe muszą zostać zakodowane w sposób umożliwiający dopasowanie do modelu.
 - d) Usuwanie wartości odstających – wartości ekstremalne znacząco odbiegające od rozkładu cech mogą zakłócać proces uczenia, prowadząc do błędnego dopasowania modelu i nadmiernej wrażliwości na szum. Ich identyfikacja odbywa się m.in. za pomocą analizy rozkładów i testów statystycznych (Han i in., 2012).
 - e) Skalowanie danych – do przeprowadzenia tego procesu stosowane są zazwyczaj następujące techniki:
 - i) Normalizacja Min-Max (*ang. Min-Max scaling*) – polega na przekształceniu wartości cechy wejściowej w taki sposób, aby mieściły się one w określonym przedziale – najczęściej od 0 do 1. Metoda ta zachowuje relacje pomiędzy oryginalnymi wartościami, jednocześnie zapewniając ich ujednoliconą skalę. Transformacja ta wykonywana jest zgodnie z Równaniem 6.4:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (6.4)$$

gdzie:

x – wartość oryginalna,

$x_{\min}$ – minimalna wartość w zbiorze danych,

$x_{\max}$ – maksymalna wartość w zbiorze danych,

x' – znormalizowana wartość po przekształceniu.

- ii) Normalizacja Z-score (standaryzacja) – polega na przeskalowaniu wartości zmiennej w taki sposób, aby jej średnia arytmetyczna wynosiła 0, a odchylenie standardowe 1. Proces ten umożliwia porównywanie wartości pochodzących z różnych rozkładów lub cech o różnych skalach, co jest szczególnie istotne w kontekście metod statystycznych oraz modeli uczenia maszynowego opartych na założeniu o normalności rozkładu danych. Normalizacja Z-score wykonywana jest zgodnie z Równaniem 6.5:

$$z = \frac{x - \bar{x}}{s} \quad (6.5)$$

gdzie:

x – wartość oryginalna,


$\bar{x}$ – średnia arytmetyczna zmiennej,

s – odchylenie standardowe zmiennej,

z – wartość standaryzowana (Z-score).

- f) Ekstrakcja i selekcja cech – obejmuje wydobycie nowych, bardziej przydatnych cech (np. transformacje logarytmiczne, funkcje nieliniowe), a także usuwanie cech nieistotnych i tych silnie skorelowanych – nie wnoszących wartości analitycznej, a jedynie zwiększających wymiarowość i złożoność obliczeniową (Jafari, 2022).

Efektywnie przeprowadzony proces wstępnego przetwarzania danych zwiększa stabilność modelu, poprawia jego zdolność do uogólniania oraz umożliwia osiągnięcie wyższych wartości metryk ewaluacyjnych. Bez niego niemożliwe jest osiągnięcie wiarygodnych i powtarzalnych wyników uczenia maszynowego.



Rysunek 6.11. Schemat postępowania w procesie przygotowania danych dla modeli ML
(opracowanie własne na podstawie Al.-jabery Khalid, 2020)


W statystyce eksploracyjna analiza danych EDA stanowi podejście polegające na systematycznym badaniu zbiorów danych w celu identyfikacji i podsumowania ich podstawowych charakterystyk. Analiza ta często wykorzystuje wykresy statystyczne oraz inne metody wizualizacji danych, umożliwiające uchwycenie istotnych wzorców i zależności. Stosowanie modeli statystycznych w ramach EDA

jest opcjonalne – głównym celem tego podejścia jest natomiast poznanie informacji zawartych w danych wykraczających poza formalne modelowanie. W ten sposób EDA odróżnia się od tradycyjnego testowania hipotez, w którym wybór modelu następuje przed przystąpieniem do analizy danych (Baillie i in., 2022). Znajduje zastosowanie w metodach wspomagających redukcję wymiarowości, tj.:

- a) Skalowanie wielowymiarowe MDS (*ang. multidimensional scaling*).
 - b) Analiza głównych składowych PCA.
 - c) Wieloliniowa analiza głównych składowych (*ang. multilinear PCA*).
 - d) Nieliniowa redukcja wymiarowości NLDR (*ang. nonlinear dimensionality reduction*).
 - e) Ikonografia korelacji (*ang. iconography of correlations*).
- 4) **Podział danych** – w ramach tego etapu cały dostępny zbiór danych zostaje rozdzielony na podzbiory, z których każdy pełni odrębną funkcję w procesie trenowania i weryfikacji modelu. Podział ten umożliwia ocenę uogólniającej zdolności modelu oraz minimalizację błędów wynikających z nadmiernego lub niedostatecznego dopasowania. W literaturze przedmiotu wyróżnia się trzy podstawowe zbiory danych (Burkov, 2019):
- a) Zbiór treningowy – wykorzystywany do właściwego procesu uczenia modelu. Na jego podstawie model aktualizuje swoje parametry wewnętrzne (np. wagi), identyfikuje wzorce i konstruuje funkcję decyzyjną umożliwiającą klasyfikację bądź prognozowanie.
 - b) Zbiór walidacyjny (opcjonalny) – stosowany w celu strojenia hiperparametrów modelu oraz do monitorowania jego ogólnej zdolności generalizacji. Umożliwia wykrycie i przeciwdziałanie zjawiskom nadmiernego dopasowania oraz niedostatecznego dopasowania do danych treningowych. Walidacja działania modelu na zbiorze walidacyjnym, który nie był wykorzystywany w procesie trenowania, pozwala na optymalizację jego architektury i parametrów.
 - c) Zbiór testowy – przeznaczony do końcowej oceny wydajności modelu po zakończeniu procesu treningu i strojenia. Służy do oszacowania skuteczności modelu na nowych danych, co stanowi podstawę do oceny jego praktycznej przydatności.

Zastosowanie zbioru walidacyjnego staje się szczególnie istotne w przypadku modeli o wysokiej złożoności i licznych hiperparametrach, gdzie ryzyko nadmiernego lub niedostatecznego dopasowania jest zwiększone (Rysunek 6.12.). Choć uniwersalna strategia podziału danych nie istnieje, w praktyce często stosowanym schematem

jest proporcja: 70% – zbiór treningowy / 15% – zbiór walidacyjny / 15% – zbiór testowy. W sytuacjach, w których rezygnuje się ze zbioru walidacyjnego (np. przy prostszych modelach), dopuszczalny jest również podział: 70% – trening / 30% – test (Al'Aref i in., 2019).



Rysunek 6.12. Wizualizacja dopasowania do danych dla modeli klasyfikacyjnych i regresyjnych (opracowanie własne na podstawie What Is Overfitting?, 2025)

- 5) **Wybór modelu** – dobór odpowiednich modeli uczenia maszynowego uzależniony jest od szeregu czynników determinujących zarówno charakter zadania analitycznego, jak i warunki jego realizacji. Wśród najważniejszych aspektów wpływających na wybór modelu można wymienić:
 - a) Klasa problemu (np. klasyfikacja, regresja, detekcja anomalii).
 - b) Rozmiar i dostępność zbioru danych.
 - c) Właściwości danych (np. rozkład cech, liczba wymiarów, obecność szumów).
 - d) Dostępność narzędzi i zasobów obliczeniowych.
 - e) Czas wymagany na proces trenowania modelu.
 - f) Stopień interpretowalności modelu.

Zalecaną praktyką, powszechnie stosowaną w procesie modelowania, jest równoległe trenowanie i testowanie wielu modeli (Tabaszewski, 2008). Podejście to umożliwia obiektywne porównanie ich właściwości na wspólnym zbiorze danych oraz wybór modelu, który najlepiej spełnia założone kryteria.

- 6) **Trenowanie modelu** – celem tego kroku jest umożliwienie modelowi identyfikacji ukrytych wzorców oraz zależności w danych wejściowych. Charakter tego procesu różni się w zależności od wybranego paradygmatu uczenia.

W przypadku uczenia nadzorowanego, model uczy się poprzez iteracyjne porównywanie generowanych prognoz z rzeczywistymi wartościami (etykietami), dążąc do minimalizacji funkcji błędu, która kwantyfikuje rozbieżność pomiędzy wartościami przewidywanymi a obserwowanymi. Na tej podstawie model aktualizuje swoje parametry, co umożliwia mu lepsze dopasowanie do wzorców występujących w danych.

W uczeniu nienadzorowanym, proces trenowania przebiega bez dostępu do etykiet klas. Celem modelu jest odkrycie wewnętrznej struktury danych, np. poprzez wykrywanie skupień czy redukcję wymiarowości. Przykładowo, algorytmy klastrowania grupują obserwacje w zbiory (klastry) na podstawie ich wzajemnego podobieństwa, bez wcześniejszej wiedzy o przynależności klasowej (Chen i Yan, 2015).

W przypadku uczenia przez wzmacnianie, model – określany tutaj mianem agenta – uczy się poprzez interakcję z dynamicznym środowiskiem. W odpowiedzi na wykonane działania agent otrzymuje sygnały nagrody lub kary i przechodzi do kolejnych stanów środowiska. Mechanizm ten ma na celu maksymalizację długoterminowego zysku (sumy skumulowanych nagród), przy czym przejścia pomiędzy stanami często mają charakter stochastyczny i są częściowo nieznane (Burkov, 2019).

Każdy z wymienionych paradygmatów wymaga odmiennych metod treningu oraz oceny skuteczności modelu, dostosowanych do specyfiki problemu i rodzaju dostępnych danych.

- 7) **Ewaluacja** – po zakończeniu procesu trenowania modelu konieczne jest przeprowadzenie jego ewaluacji, której celem jest ocena zdolności modelu do generalizacji, czyli poprawnego działania na wcześniej niewidzianych danych. Ocena ta pozwala określić, w jakim stopniu model spełnia założenia problemu i jak efektywnie go rozwiązuje. Do ewaluacji modeli wykorzystuje się odpowiednie metryki oceny, których wybór zależy od klasy problemu (np. klasyfikacja, regresja), zastosowanego modelu oraz konkretnego celu analitycznego. Metryki te umożliwiają ilościowe ujęcie skuteczności modelu, co stanowi podstawę do jego porównywania, możliwościach poprawy oraz podejmowania decyzji o wdrożeniu w środowisku

produkcyjnym. Miary oceny skuteczności modeli dedykowanych problemom regresji (wykorzystywanych w niniejszej dysertacji) zostały opisane w Rozdziale 6.3.

- 8) **Strojenie hiperparametrów** – w zależności od wyników ewaluacji oraz stopnia złożoności modelu, dopuszczalne jest modyfikowanie wartości hiperparametrów, a proces ten określa się mianem strojenia. Hiperparametry stanowią zewnętrzne względem procesu trenowania parametry sterujące przebiegiem uczenia się, które nie podlegają bezpośredniej optymalizacji podczas treningu. Do typowych przykładów hiperparametrów należą, np.: współczynnik szybkości uczenia, liczba warstw ukrytych w sieciach neuronowych czy liczba określająca głębokość drzew decyzyjnych. Głównym celem optymalizacji hiperparametrów jest identyfikacja takiego zestawu wartości, który pozwoli na maksymalizację efektywności działania modelu oraz uzyskanie najlepszych wyników (Mamczur, 2022).
- 9) **Testowanie i walidacja końcowa** – następnie model poddawany jest ocenie na dedykowanym, wcześniej niewykorzystywanym zbiorze testowym. Celem tego działania jest obiektywne oszacowanie zdolności modelu do generalizacji, czyli jego skuteczności w przewidywaniu wyników dla nowych, nieznanych danych. Walidacja końcowa umożliwia identyfikację ewentualnych problemów i wiarygodności modelu w kontekście jego praktycznego zastosowania. W tym etapie stosuje się różnorodne metryki oceny, dostosowane do klasy problemu i rodzaju modelu, z myślą o jego finalnej ewaluacji. Ostateczne wyniki testowania i walidacji mają fundamentalne znaczenie dla decyzji dotyczących wdrożenia modelu w środowisku produkcyjnym lub dalszej jego optymalizacji.
- 10) **Wdrożenie** – stanowi końcowy etap procesu projektowania i trenowania modelu, którego celem jest jego integracja z rzeczywistym środowiskiem operacyjnym. Oznacza to przeniesienie modelu z fazy eksperymentalnej do zastosowań praktycznych, w których będzie on przetwarzał nowe, napływające dane i generował prognozy lub decyzje wspierające procesy biznesowe, technologiczne bądź analityczne. Proces wdrożenia może obejmować szereg działań technicznych, tj.: eksport wytrenowanego modelu do odpowiedniego formatu, przygotowanie interfejsów API (*ang. application programming interface*) do komunikacji z innymi systemami, zapewnienie infrastruktury obliczeniowej (np. serwery lokalne lub chmura obliczeniowa)


oraz implementację mechanizmów monitorowania jego wydajności. Istotnym aspektem wdrożenia jest również zapewnienie stabilności, skalowalności i bezpieczeństwa działania modelu.

11) Monitorowanie i utrzymanie – wdrożony model powinien być stale monitorowany pod kątem poprawności działania, a także regularnie aktualizowany – szczególnie w sytuacjach, gdy dane wejściowe ulegają zmianom, co może negatywnie wpływać na skuteczność modelu. Dlatego proces wdrożenia nie kończy się na uruchomieniu modelu, lecz często stanowi początek jego cyklu życia w środowisku produkcyjnym, który wymaga bieżącej kontroli i adaptacji. Obejmuje to śledzenie takich aspektów jak: dokładność predykcji / klasyfikacji, rozkład danych wejściowych, częstość błędów, czas odpowiedzi czy odsetek odrzuconych zapytań. Szczególne znaczenie ma wykrywanie zjawisk, tj.:

- a) Data drift – zmiana rozkładu danych wejściowych.
- b) Concept drift – zmiana relacji między danymi a etykietami wynikowymi.
- c) Model decay – stopniowy spadek poprawności działania modelu w czasie.

Utrzymanie modelu obejmuje działania naprawcze i adaptacyjne, np.: okresowe ponowne trenowanie modelu na nowych danych, aktualizacja hiperparametrów, dostosowanie architektury modelu, a także zarządzanie jego wersjami. Może także wiązać się z przeprowadzaniem audytów modelu pod kątem zgodności z wymaganiami regulacyjnymi i panującymi standardami.

Całość przedstawionego cyklu (Rysunek 6.13), wskazuje na konieczność podejścia systemowego i ciągłej iteracji, co pozwala zapewnić nie tylko wysoką skuteczność opracowanego rozwiązania mierzoną odpowiednimi metrykami ewaluacyjnymi, lecz także jego stabilność i odporność na zmieniające się środowisko. Rzetelnie przeprowadzony cykl gwarantuje, że model zachowuje swoją przydatność praktyczną oraz może być bezpiecznie utrzymywany w środowisku produkcyjnym. Regularne monitorowanie oraz ponowne dostrajanie sprawiają, że funkcjonowanie modelu pozostaje zgodne z założeniami projektowymi.



Rysunek 6.13. Cykl życia modelu uczenia maszynowego (opracowanie własne)

6.3 Ocena działania modelu dla problemu regresji

Ze względu na to, że problem badawczy niniejszej dysertacji został określony jako problem regresyjny, podjęto decyzję o zastosowaniu i porównaniu metod dedykowanych modelowaniu zależności ilościowych. Wybór ten wynika z potrzeby przewidywania wartości zmiennej objaśnianej na podstawie zestawu zmiennych objaśniających, co jest charakterystyczne dla problemów regresyjnych. Analiza porównawcza różnych metod umożliwia ocenę ich skuteczności w kontekście dopasowania modelu, odporności na wartości odstające oraz interpretowalności wyników. Do oceny działania i porównania modeli rozwiązujących problemy regresji, stosuje się następujące mierniki (Chicco i in., 2021):

- 1) Błąd średniokwadratowy MSE (*ang. Mean Squared Error*) – suma kwadratów różnic między wartością rzeczywistą a prognozowaną. Używana do mierzenia ogólnego błędu predykcji w problemach regresji. Oblicza się go z wykorzystaniem Równania 6.6:

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (6.6)$$

gdzie:

m – liczba obserwacji;

y_i – i -ta obserwowana wartość;

$\hat{y}_i$ – odpowiadająca jej wartość prognozowana.

- 2) Pierwiastek błędu średniokwadratowego RMSE (*ang. Root Mean Squared Error*) – mierzy średnią różnicę pomiędzy przewidywanymi wartościami a rzeczywistymi wartościami docelowymi. Im niższa wartość RMSE, tym lepiej model radzi sobie z aproksymacją rzeczywistych danych. Matematyczny zapis został przedstawiony za pomocą Równania 6.7:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}, \quad (6.7)$$

gdzie:

m – liczba obserwacji;

y_i – i -ta obserwowana wartość;

$\hat{y}_i$ – odpowiadająca jej wartość prognozowana.

- 3) Średni błąd bezwzględny MAE (*ang. Mean Absolute Error*) – intuicyjny i łatwy do interpretacji, traktujący równomiernie wszystkie odchylenia. Jest mało wrażliwy na wartości odstające i oblicza się go zgodnie z Równaniem 6.8:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6.8)$$

gdzie:

n – liczba obserwacji;

y_i – i -ta obserwowana wartość;

$\hat{y}_i$ – odpowiadająca jej wartość prognozowana.

- 4) Średni bezwzględny błąd procentowy MAPE (*ang. Mean Absolute Percentage Error*) – wyraża błąd predykcji jako procent wartości rzeczywistej. Zastosowanie go jest nieodpowiednie, gdy wartości rzeczywiste są bliskie zeru. Obliczany według Równania 6.9:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (6.9)$$

gdzie:

n – liczba obserwacji;

y_i – i -ta obserwowana wartość;

$\hat{y}_i$ – odpowiadająca jej wartość prognozowana.

- 5) Współczynnik determinacji R^2 – określa jaka część wariancji zmiennej zależnej jest wyjaśniana przez model. Wyraża stopień dopasowania modelu do danych. Miara R^2 przyjmuje wartości od 0 do 1, gdzie wartość bliska 1 oznacza bardzo dobrą jakość modelu, natomiast 0 słabą jakość modelu. Modele osiągające wartości ≥ 0.7 uznaje się za dobre. R^2 wyznaczany jest zgodnie z Równaniem 6.10:

$$R^2 = 1 - \frac{MSE(model)}{MSE(odniesienie)} \quad (6.10)$$

gdzie:

$MSE(model)$ – błąd średniokwadratowy predykcji do rzeczywistej wartości;

$MSE(odniesienie)$ – błąd średniokwadratowy średniej predykcji do rzeczywistej wartości.

- 6) Skorygowany współczynnik determinacji ‘Adjusted R^2 ’ – uwzględnia liczbę zmiennych w modelu i wielkość próby, zapobiegając sztucznemu zawyżaniu wartości R^2 przy dodawaniu kolejnych predyktorów. Wyznaczany zgodnie z Równaniem 6.11:

$$Adjusted R^2 = 1 - (1 - R^2) \frac{n - 1}{n - p - 1} \quad (6.11)$$

gdzie:

n – liczba obserwacji;

p – liczba predyktorów.

7. Część badawcza

W dotychczasowych rozdziałach pracy przedstawiono zagadnienia związane z budową, technologią wytwarzania, metodami testowania oraz jednorodnością opon. Omówiono także aktualne kierunki badań opon samochodowych, ze szczególnym uwzględnieniem rosnącego znaczenia metod uczenia maszynowego, a także wskaźników umożliwiających ocenę modeli predykcyjnych. Analiza ta stanowi podstawę do podjęcia badań ukierunkowanych na praktyczne wykorzystanie wspomnianych metod obliczeniowych w doskonaleniu procesów produkcyjnych. Celem i hipotezą niniejszej rozprawy doktorskiej są:

Cel:

Opracowanie modelu generującego w czasie rzeczywistym wartości stożkowatości opon na podstawie danych wejściowych z procesu ich konfekcji.

Hipoteza:

Na etapie pomiaru zmiennych wejściowych komponentów składowych danej opony podczas procesu konfekcji możliwa jest skuteczna predykcja jej stożkowatości.

W części badawczej skoncentrowano się na działaniach dążących do opracowania modelu przewidującego stożkowatość opon stanowiącej istotny parametr jakościowy. Przekroczenia jej limitu znajdują się wysoko w hierarchii problemów produkcyjnych. Zmienność tej wielkości pozostaje w dużej mierze konsekwencją właściwości i rozmieszczenia materiałów używanych na etapie konfekcji, co wskazuje na możliwość prognozowania jej wartości na podstawie pomiarów wykonywanych w trakcie tego procesu.

Celem badań jest opracowanie modelu predykcyjnego umożliwiającego przewidywanie stożkowatości opon na podstawie danych pomiarowych uzyskiwanych w procesie konfekcji. Sformułowanie „skuteczna predykcja” w niniejszej rozprawie, jest rozumiane jako zdolność modelu do prawidłowego przewidzenia, czy opona znajdzie się w narzuconym indywidualnie dla niej limicie stożkowatości. W tej części pracy przedstawiono charakterystykę danych wykorzystanych w badaniach, metodykę ich przetwarzania oraz zestaw modeli uczenia maszynowego poddanych analizie porównawczej. Omówiono także wyniki przeprowadzonych badań oraz dokonano oceny praktycznych możliwości wdrożenia opracowanego rozwiązania w warunkach przemysłowych. Z myślą o przedstawieniu logiki działań podejmowanych

w części badawczej, w Tabeli 7.1. zaprezentowano poszczególne jej etapy dążące do uzyskania zamierzonego celu.

Tabela 7.1. Etapy realizowanych działań części badawczej pracy doktorskiej (opracowanie własne)

Lp.	Etap prac	Uzasadnienie postępowania
1	Omówienie sposobu rejestracji danych wejściowych i danych wyjściowych.	Przedstawienie przedmiotu badań oraz określenie obszaru realizowanych prac na tle całego procesu produkcji opon.
2	Opis dotychczasowego przepływu danych wejściowych i wyjściowych w przedsiębiorstwie.	Zaprezentowanie stanu wejściowego (przed rozpoczęciem badań i wdrożeniem opracowanego narzędzia).
3	Przedstawienie uzasadnienia wyboru zmiennych wejściowych, przygotowanie i eksploracyjna analiza danych zbiorów I i V.	Właściwy dobór zmiennych wejściowych do modelu predykcji stożkowatości dla skrajnych rozmiarów opon z portfolio możliwości produkcyjnych maszyn VMI MAXX.
4	Poszukiwanie odpowiednich kryteriów porównawczych dla modeli dedykowanych do problemów regresji.	Rzetelna ocena trenowanych modeli, odnalezienie mierników stanowiących mianownik doboru modelu do dalszych kroków badawczych.
5	Analiza zastosowania regresji liniowej wielu zmiennych.	Określenie charakteru badanych powiązań, uzasadnienie użycia metod do testowania zależności nieliniowych.
6	Analiza zastosowania modelu MLP.	Obserwacja efektu modelowania uzyskanego za pomocą sztucznych sieci neuronowych.
7	Analiza zastosowania modeli opartych na drzewach decyzyjnych.	Zwiększenie puli porównawczej zastosowanych metod poprzez uzyskanie rezultatu modelowania z wykorzystaniem drzew decyzyjnych.
8	Analiza dotychczasowych wyników	Ocena i wytypowanie najlepszego modelu z zastosowaniem 5 zmiennych wejściowych.

9	Dodanie szóstej zmiennej wejściowej do modelowania.	Osiągnięcie szerszej informacji zwrotnej z procesu konfekcji opon, zwiększenie precyzji predykcji uzyskanych modeli, powtórna weryfikacja osiągniętych rezultatów.
10	Obserwacja zachowania modelu na nieznanych zbiorach danych (II, III, IV, VI) pochodzących z produkcji szerszej grupy rozmiarów opon.	Ocena działania modelu dla pośrednich wielkości rozmiarów opon i jego uniwersalności w stosunku do charakteru produkcji przedsiębiorstwa. Walidacja modelu dedykowanego do wdrożenia w przedsiębiorstwie poprzez osiągnięcie zsyntetyzowanych wniosków.

7.1 Przedmiot badań

7.1.1 Pomiary komponentów składowych opony na maszynie VMI MAXX

W tym podrozdziale przedstawiono sposób pomiarów materiałów, których rezultaty są istotne dla prawidłowego działania ostatecznej wersji modelu. Maszyna konfekcyjna VMI MAXX wykonuje pomiary komponentów składowych opony podczas I fazy konfekcji w następujący sposób:


1) Zespół PA

Pomiar długości i szerokości zespołu PA odbywa się na pasie przenośnika bezpośrednio przed jego nałożeniem na bęben karkasu (Rysunek 7.1.).

Za pomiar długości odpowiada system wykrywania krawędzi początku i końca materiału składający się z rolki detekcji oraz fotokomórki mierzy długość materiału. Fotokomórka wykrywa krawędzie materiału, natomiast enkoder w trakcie ruchu przenośnika z umieszczonym na nim materiałem zlicza ilość obrotów rolki detekcji pomiędzy napotkanymi krawędziami. Oprogramowanie maszyny przelicza obroty na długość liniową [mm] materiału, która następnie zapisywana jest w Bazie Danych Produkcyjnych maszyny VMI MAXX.

Pomiar szerokości natomiast przeprowadzany jest przez system prowadzenia karkasu składający się z czterech kamer zamontowanych w stałych miejscach, które skanują krawędzie materiałów. Próbkę pomiarową pobierane są podczas transportu materiału zespołu PA

z przenośnika noża na przenośnik aplikujący, które następnie zapisywane są w Bazie Danych Produkcyjnych maszyny VMI MAXX. Dodatkowo, dzięki tym pomiarom system sterownika prowadzenia karkasu może prawidłowo zrównać bęben karkasu z aplikatorem.




Rysunek 7.1. Aplikator karkasu: 1 - rolka piankowa, 2 - detektor krawędzi początku i końca materiału, 3 - system prowadzenia karkasu, 4 - silnik napędowy, 5 - pas przenośnika (opracowanie własne na podstawie materiałów własnych przedsiębiorstwa)

2) Opasania i bieznik

Pomiary długości opasania 1, opasania 2 oraz bieznika odbywają się w analogiczny sposób na dedykowanych dla nich przenośnikach. Za pomiar szerokości opasania 1, opasania 2 oraz bieznika a także ich prawidłowe wycentrowanie na bębnie B&T odpowiedzialne są dedykowane im systemy prowadzenia. Ze względu na podobieństwo zasady przeprowadzania pomiarów dla tych materiałów poniżej zostanie ona omówiona na przykładzie materiału bieznika.

Urządzenie pomiaru długości bieznika znajduje się nad przenośnikiem podającym materiał bieznika do przenośnika noża (Rysunek 7.2.). Urządzenie pomiaru długości składa się z rolki wykrywania krawędzi i fotokomórki. Przenośnik noża jest wyposażony w silnik sterowany


częstotliwościowo, natomiast przenośnik podający jest wyposażony w serwonapęd. Za transport materiału do przenośnika noża odpowiadają pracujące razem dwa napędy. Gdy krawędź materiału styka się z rolką wykrywania krawędzi, fotokomórka aktywuje się, a sterownik serwomotoru zaczyna zliczać impulsy silnika do chwili osiągnięcia wymaganej długości. Wynik dokładnego pomiaru zapisywany jest w Bazie Danych Produkcyjnych maszyny VMI MAXX. W uproszczeniu: wymagana długość = odległość nóż/fotokomórka (stała) + impulsy silnika. Po osiągnięciu wymaganej nastawy transport materiału jest zatrzymywany, a nóż tnący materiał.



Rysunek 7.2. Zespół przenośników bieżnika: 1 – materiał, 2 - urządzenie pomiaru długości, 3- silnik napędowy (przenośnik podający), 4 - czujnik zbliżeniowy, 5 - rolka wykrywania krawędzi, 6 – przenośnik, 7 - silnik napędowy (przenośnik noża) (opracowanie własne na podstawie materiałów własnych przedsiębiorstwa)

System prowadzenia bieżnika (Rysunek 7.3.A) odpowiada za pomiar szerokości materiału bieżnika oraz jego prawidłowe wycentrowanie na bębnie B&T. Na przenośniku aplikującym znajduje się mała szczelina, nad którą zamontowana jest kamera, a pod nią – listwa LED. Światło LED ułatwia kamerze generowanie obrazów, które następnie są wykorzystywane do wykrywania materiału na przenośniku. Koder napędzany taśmą przenośnika generuje

impulsy informujące kamerę o momencie zrobienia zdjęcia. Dzięki temu każde zdjęcie jest wykonywane w cyklicznie ustalonej odległości (zgodnie z narzuconą częstotliwością próbkowania). Wartości zmierzone przez kamerę są wysyłane do kontrolera PLC oraz zapisywane w Bazie Danych Produkcyjnych maszyny VMI MAXX. Kontroler PLC wykorzystuje je do aktywnego centrowania materiału na bębnie B&T poprzez przesuwanie go na boki (Rysunek 7.3.B).




Rysunek 7.3. System prowadzenia bieżnika (A): 1 – PLC, 2 – kamera, 3 – koder, 4 - listwa LED, 5 – bęben BT. Aktywne centrowanie materiału na bębnie B&T (B) (opracowanie własne na podstawie materiałów własnych przedsiębiorstwa)

7.1.2 Pomiary wielkości opisujących jednorodność opon na maszynach TUO i Rim Flow oraz dotychczasowy przepływ danych

Po procesie wulkanizacji, opony transportowane są przenośnikami taśmowymi bezpośrednio do maszyn służących do pomiaru jednorodności (TUO i Rim Flow). Wielkości

opisujące jednorodność opon mierzone są zgodnie z normą (Polski Komitet Normalizacyjny, 2002) w warunkach określonych wymaganiami klienta (opony OE) lub w aktualnej wersji (ETRTO, 2025) (dla opon TRADE). Wszystkie rezultaty zapisywane są w Bazie Danych UNIF. Dotychczasowy przepływ danych w przedsiębiorstwie został przedstawiony na Rysunku 7.4. Przed zapisem w dedykowanych bazach danych zarówno dane wejściowe jak i dane wyjściowe ulegają przetworzeniu do postaci narzuconej przez Dział TS (Dział Technologiczny) aby sposób ich uporządkowania odpowiadał bieżącym potrzebom przedsiębiorstwa, np. w celu uzyskania jak najszybszej odpowiedzi i wypracowania środków zaradczych na napotkane problemy produkcyjne i pojawiające się defekty opon.



Rysunek 7.4. Dotychczasowy przepływ danych wejściowych i wyjściowych w przedsiębiorstwie (opracowanie własne)

Ze względu na zaistnienie nowej możliwości rejestracji danych wejściowych na maszynach konfekcyjnych VMI MAXX, którymi są rezultaty pomiarów wymiarowych komponentów

składowych opony, jako wielkość będącą przedmiotem predykcji modelu stanowiącego przedmiot badań niniejszej dysertacji przyjęto stożkowatość. Wynika to z faktu, iż przekroczenia limitu tej wielkości opisującej jednorodność opon wynikają głównie z zaburzenia symetrii materiałów względem osi opony oraz niedotrzymania specyfikacji ich szerokości (Nakajima, 2019).

7.2 Gromadzenie, przygotowanie i analiza danych

7.2.1 Rejestracja i wstępne przetwarzanie danych

Dążąc do rozwiązania **problemu zdefiniowanego** w celu i hipotezie badawczej niniejszej pracy doktorskiej rozpoczęto od zweryfikowania dokładności pomiarowej czujników maszyny VMI MAXX odpowiadających za zbiór danych wejściowych do budowanego modelu. W przypadku wykrycia rozbieżności pomiędzy pomiarem fizycznym a wynikiem podawanym przez oprogramowanie, przeprowadzono **kalibrację** danego czujnika zgodnie z instrukcją techniczną maszyny VMI MAXX.

Spośród wszystkich wielkości zapisywanych przez maszynę VMI MAXX dla każdej sztuki opony, wybrano **5 zmiennych wejściowych** (Tabela 7.2.) zasugerowanych przez eksperta dziedzinowego. Zmienne te wybrano mając na uwadze istotę zjawiska stożkowatości, które opisuje utrzymanie zadanego toru jazdy podczas ruchu opony. W nowoczesnych konstrukcjach opon odpowiadają za to głównie bieżnik (zapewniający kontakt opony z podłożem) oraz opasania (zapewniające sztywność opony) (Rodgers i Waddell, 2005). Zaburzenie symetrii tych materiałów względem osi opony i niedotrzymanie specyfikacji ich szerokości to główne powody przekraczania limitu stożkowatości (Nakajima, 2019). Co więcej, wymienione komponenty stanowią ok. 50% całkowitej masy opony o konstrukcji standardowej⁴, zatem mają one znaczący wpływ na ewentualne przesunięcie jej środka masy. Wzięto także pod uwagę szerszy sens fizyczny zjawiska stożkowatości, który został już przybliżony w Rozdziale 4.3.5 niniejszej dysertacji. Kluczowy wpływ zmiennych wymienionych w Tabeli 7.2. został dodatkowo potwierdzony wieloletnim doświadczeniem przedsiębiorstwa w codziennym eliminowaniu defektów oraz odnajdowania ich przyczyn w dużej liczbie rozmiarów opon. Ponadto w celu uzasadnienia wyboru zmiennych, przeprowadzono eksploracyjną analizę danych.

⁴ W kontekście rozważań niniejszej rozprawy doktorskiej, „konstrukcja standardowa opony” wskazuje na oponę niezawierającą w swojej budowie wzmacniającej wkładki runflatowej, ponieważ tylko dla takiego typu rozmiarów opon realizowane były badania.

Tabela 7.2. Zmienne wejściowe wybrane przez eksperta dziedzinowego (opracowanie własne)


ZMIENNA WEJŚCIOWA	OPIS
BR1_WIDTH_MEASURED	Średnia wartość pomiaru szerokości pierwszego opasania dedykowanego do danej opony zmierzona przez system prowadzenia opasań [mm]
BR2_WIDTH_MEASURED	Średnia wartość pomiaru szerokości drugiego opasania dedykowanego do danej opony zmierzona przez system prowadzenia opasań [mm]
TD_WIDTH_MEASURED	Średnia wartość pomiaru szerokości bieżnika dedykowanego do danej opony zmierzona przez system prowadzenia bieżnika [mm]
1BAP_BODY_AVG_OFF_CENTER	Średnia wartość przecentrowania pierwszego opasania dedykowanego do danej opony w odniesieniu do lasera centralnego bębna B&T [mm]
2BAP_BODY_AVG_OFF_CENTER	Średnia wartość przecentrowania drugiego opasania dedykowanego do danej opony w odniesieniu do lasera centralnego bębna B&T [mm]

Do badań wykorzystano zbiory danych przedstawione w Tabeli 7.3.

Tabela 7.3. Zbiory danych używane do badań (opracowanie własne)

ZBIÓR DANYCH	ROZMIAR OPONY	LICZBA REJESTRÓW (OPON) W ZBIORZE	ZAKRES CZASU PRODUKCJI
I	285/35 R22 106Y XL	7006	07-09.2021
II	285/35 R22 106Y XL	14352	03-06.2024
III	215/50 R18 92W	10239	02-06.2024
IV	235/55 R19 101T	10212	02-06.2024
V	205/55 R19 97V	6937	02-05.2024
VI	225/45 R18 91W	10284	03.2024

Dane do wymienionych zbiorów zostały pobrane z historycznego rejestru, powstałego podczas rzeczywistej produkcji masowej opon w przedsiębiorstwie. Schemat rejestracji i przygotowania danych na tle przepływu procesu produkcji opon przedstawiono na Rysunku 7.5. Pomiary wymiarów komponentów składowych opony z etapu konfekcji (przeprowadzane przez maszynę VMI MAXX) oraz wyniki pomiarów stożkowatości opony z etapu inspekcji końcowej (wykonywane przez maszyny Rim Flow i TUO) zostały zarejestrowane w dedykowanych bazach danych. Dla każdego badanego rozmiaru opony zintegrowano dane z tych baz poprzez zestawienie wybranych zmiennych wejściowych ze zmienną wyjściową dla danego kodu kreskowego (sztuki opony).



Rysunek 7.5. Schemat rejestracji i przygotowania danych na tle procesu produkcji opon
(opracowanie własne)

Zmienne wejściowe każdego zbioru były zawsze rejestrowane przez tę samą maszynę konfekcyjną (dane produkcji z jednej maszyny dla danego rozmiaru opon). Nieścisłości w danych zostały skorygowane (**oczyszczanie danych**) – usunięto wartości zdublikowane (z powodu np. drugiego lub kolejnego pomiaru jednorodności) oraz wiersze zawierające puste komórki (pojawiające się dlatego, że np. opona przez wzgląd na inne defekty nie dotarła do etapu pomiaru jednorodności). W przypadku danych o wartości dyskusyjnej, decyzję o naprawieniu / usunięciu rekordu podejmowano na podstawie analizy statystycznej oraz znajomości problemów produkcyjnych lub jakościowych występujących w danym okresie. Dla wszystkich testowanych metod dane (każda zmienna wejściowa i wyjściowa) zostały **znormalizowane** do zakresu $<0; 1>$, ponieważ powinny charakteryzować się tym samym rzędem wielkości, aby zapewnić wiarygodne porównanie różnych modeli. Przygotowane w ten sposób dane zostały implementowane do wszystkich modeli badanych w ramach niniejszej dysertacji.

7.2.2 Eksploracyjna analiza danych

W Tabeli 7.4. zawarto limity stożkowatości dla badanych zbiorów danych, które są zgodne z wymaganiami klienta lub wewnętrznymi standardami przedsiębiorstwa.

Tabela 7.4. Limity stożkowatości badanych zbiorów (opracowanie własne)

ZBIÓR DANYCH	ROZMIAR OPONY	LIMIT CON [N]
I	285/35 R22 106Y XL	$<-30; 30>$
II	285/35 R22 106Y XL	$<-40; 20>$
III	215/50 R18 92W	$<-35; 45>$
IV	235/55 R19 101T	$<-45; 35>$
V	205/55 R19 97V	$<-95; 95>$
VI	225/45 R18 91W	$<-38; 62>$

W Tabeli 7.5. przedstawiono tolerancje wymiarowe zmiennych wejściowych, które są zgodne z procesem konfekcji i mają zastosowanie we wszystkich badanych zbiorach danych (I-VI).

Tabela 7.5. Tolerancje wymiarowe zmiennych wejściowych (opracowanie własne)

ZMIENNA WEJŚCIOWA [mm]	TOLERANCJA [mm]
BR1_WIDTH_MEASURED	+/-3
BR2_WIDTH_MEASURED	+/-3
TD_WIDTH_MEASURED	+/-3
1BAP_BODY_AVG_OFF_CENTER	+/-1
2BAP_BODY_AVG_OFF_CENTER	+/-1

Przeprowadzono **eksploracyjną analizę danych** następujących zbiorów:

- 1) I – dane dotyczą najszerzego i najcieńszego rozmiaru opony spośród wybranych.
W czasie jego produkcji dochodziło do problemów z utrzymaniem limitu stożkowatości (generowanie złomów, dużo wartości odstających), dodatkowo w fabryce miał miejsce przestój wakacyjny.
- 2) V - dane dotyczą najwęższego i najlżejszego rozmiaru opony spośród wybranych; podczas produkcji nie odnotowano większych problemów.

Dane ze zbiorów I i V zostały wybrane jako przedmiot badań i analizy porównawczej modeli ze względu na to, że określają spektrum rozmiarów opon produkowanych na maszynach VMI MAXX (dane w nich zawarte dotyczą produkcji największego i najmniejszego rozmiaru opon). W Tabeli 7.6. zaprezentowano wartości specyfikacyjne komponentów dla zbiorów I i V. W tabeli nie uwzględniono przecentrowania opasania 1 i 2, którego domyślna wartość specyfikacyjna dla wszystkich omawianych w trakcie badań przypadków wynosi 0.

Tabela 7.6. Wartości specyfikacyjne zmiennych wejściowych (opracowanie własne)

ZMIENNA WEJŚCIOWA	Zbiór I	Zbiór V
BR1_WIDTH_MEASURED [mm]	251	181
BR2_WIDTH_MEASURED [mm]	241	171
TD_WIDTH_MEASURED [mm]	308	220


Obliczono następujące wartości podstawowych miar statystycznych zmiennych wejściowych i zmiennej wyjściowej dla zbiorów I i V: wartość średnią (AVG), odchylenie standardowe (STDEV), wartości maksymalną (MAX) i minimalną (MIN). Wyniki obliczeń zostały zestawione w Tabeli 7.7.

Tabela 7.7. Miary statystyczne zmiennych wejściowych zbiorów I i V (opracowanie własne)


Zmienna	Miara	Zbiór I	Zbiór V
BR1_WIDTH_MEASURED [mm]	AVG	252.83	181.31
	STDEV	1.62	0.80
	MIN	245.83	176.37
	MAX	257.46	183.73
BR2_WIDTH_MEASURED [mm]	AVG	241.85	171.00
	STDEV	1.46	0.83
	MIN	231.00	166.64
	MAX	245.75	173.04
TD_WIDTH_MEASURED [mm]	AVG	306.46	220.38
	STDEV	1.12	0.93
	MIN	302.70	215.57
	MAX	310.21	223.74
1BAP_BODY_AVG_OFF_CENTER [mm]	AVG	0.32	-0.51
	STDEV	1.12	0.34
	MIN	-2.87	-1.54
	MAX	2.65	0.32
2BAP_BODY_AVG_OFF_CENTER [mm]	AVG	-0.20	-0.50
	STDEV	1.05	0.40
	MIN	-3.43	-1.66
	MAX	2.29	1.41
Stożkowatość (CON) [N]	AVG	-21.05	-3.26
	STDEV	15.54	5.04
	MIN	-66.00	-20.00
	MAX	27.00	15.00

Na podstawie zestawionych wartości można stwierdzić, że proces produkcji rozmiaru ze zbioru V charakteryzował się większą stabilnością. Odchylenie standardowe szerokości opasań dla zbioru I jest ok. 2-krotnie większe, niż w zbiorze V. Przecentrowania opasań zbioru V charakteryzują się ok. 3-krotnie mniejszą wartością odchylenia standardowego w stosunku do zbioru I. Podobna sytuacja ma miejsce dla pomiaru zmiennej wyjściowej, czyli stożkowatości.

Na Rysunkach 7.6. – 7.17. przedstawiono wykresy przebiegu procesu produkcji oraz rozkłady empiryczne wartości pomiarów zmiennych wejściowych i zmiennej wyjściowej dla zbioru I. Analiza wskazuje, że w obserwowanym okresie 27.6% pomiarów stożkowatości przekroczyło jej limity (Rysunki 7.6. i 7.7.). Wartości dodatnie stanowią jedynie 10.2% wszystkich pomiarów i zawsze mieszczą się w górnym limicie. Rozkład wyników jest stanowczo przesunięty w stronę wartości ujemnych. Warto zauważyć, że 90.9% wyników koncentruje się w obszarze od $-40[N]$ do $20[N]$. Widoczna jest wyraźna zmienność sygnału w czasie – okresy fluktuacji przeplatają się z odcinkami o mniejszej zmienności, co może świadczyć o występowaniu cyklicznych zmian w badanym procesie. Możliwe jest występowanie trendów lokalnych oraz zmian losowych, które dodatkowo pogłębiają niestabilność względem ustalonych limitów. Potwierdza się zatem przypuszczenie, że wznowienie produkcji po przestoju wakacyjnym (zakres od próbki nr 3836) daje inne wyniki stożkowatości. Obliczono, że nastąpił wzrost średniej wartości do $-19[N]$ w stosunku do produkcji przed przestojem, która charakteryzowała się średnią $-27[N]$.




Rysunek 7.6. Wyniki pomiarów stożkowatości dla przebiegu procesu produkcji opon ze zbioru I
(opracowanie własne)




Rysunek 7.7. Rozkład empiryczny wartości pomiarów stożkowatości dla zbioru I (opracowanie własne)


Wyniki pomiarów szerokości opasań (Rysunki 7.8., 7.9., 7.10., 7.11.) wskazują, że były one produkowane w górnej granicy tolerancji – aż 27.5% opasań 1 i 2.5% opasań 2 przekraczało górny limit narzuconej specyfikacji. Rozstęp wynoszący 11.63[mm] dla opasania 1 i 14.75[mm] dla opasania 2 sugerują niestabilność procesu.




Rysunek 7.8. Wyniki pomiarów szerokości opasania 1 dla przebiegu procesu produkcji opon ze zbioru I (opracowanie własne)



Rysunek 7.9. Rozkład empiryczny wartości pomiarów szerokości opasania 1 dla zbioru I
(opracowanie własne)




Rysunek 7.10. Wyniki pomiarów szerokości opasania 2 dla przebiegu procesu produkcji opon ze zbioru I
(opracowanie własne)




Rysunek 7.11. Rozkład empiryczny wartości pomiarów szerokości opasania 2 dla zbioru I
(opracowanie własne)

Pomiary szerokości bieżnika (Rysunki 7.12 i 7.13.) natomiast wskazują, że był wytłaczany w dolnej granicy tolerancji – 9.7% pomiarów miało wartość poniżej dolnego limitu specyfikacji. Rozdział wartości pomiarowych jest jednak symetryczny względem średniej wartości 306.46[mm].




Rysunek 7.12. Wyniki pomiarów szerokości bieżnika dla przebiegu procesu produkcji opon ze zbioru I
(opracowanie własne)




**Rysunek 7.13. Rozkład empiryczny wartości pomiarów szerokości bieżnika dla zbioru I
(opracowanie własne)**

Największe fluktuacje zauważalne są dla przecentrowania opasań 1 i 2 (Rysunki 7.14., 7.15., 7.16. i 7.17.), których rozkłady empiryczne są wyraźnie rozdzielone na dwie grupy dotyczące produkcji przed i po przerwie letniej, kiedy doszło do średniego przesunięcia obu opasań w kierunku wartości dodatnich (czyli w prawo na bębnie B&T). Tendencja ta może być związana z jednoczesnym przesunięciem średniej wartości pomiarów stożkowatości po przestoju – również w kierunku dodatnim. Średnie wartości przecentrowania opasania 1 i 2 przed przestojem wynoszą $-0.59[\text{mm}]$ i $-0.74[\text{mm}]$, natomiast po przerwie wynoszą adekwatnie $1.46[\text{mm}]$ i $0.47[\text{mm}]$.




Rysunek 7.14. Wyniki pomiarów przecentrowania opasania 1 dla przebiegu procesu produkcji opon ze zbioru I (opracowanie własne)




Rysunek 7.15. Rozkład empiryczny wartości pomiarów przecentrowania opasania 1 dla zbioru I (opracowanie własne)

Dla przecentrowania opasania 1 poza limitem znalazło się 48.0% pomiarów a dla przecentrowania opasania 2 zarejestrowano 40.8% przekroczeń.



Rysunek 7.16. Wyniki pomiarów przecentrowania opasania 2 dla przebiegu procesu produkcji opon ze zbioru I (opracowanie własne)




Rysunek 7.17. Rozkład empiryczny wartości pomiarów przecentrowania opasania 2 dla zbioru I
(opracowanie własne)

Wystąpienie 27.6% wartości pomiarów stożkowatości poniżej limitu dolnego jednoznacznie wskazuje na problem jakościowy. Źródła tego odchylenia mogą być zarówno systemowe (np. niewłaściwe ustawienia maszynowe), jak i losowe (zakłócenia w procesie wynikające z innych przyczyn). Na skutek analizy przeprowadzonej przez Dział TS, działaniami korygującymi dla tego rozmiaru było m.in. wynegocjowanie u klienta zmiany limitów stożkowatości z $<-30[N]; 30[N]>$ na $<-40[N]; 20[N]>$. Jest to widoczne dla zbioru II (jego limity oraz zakres produkcji zostały przedstawione w Tabelach 7.3 i 7.4), który został dodany do grupy badanych zbiorów, w celu potwierdzenia wypracowanych wniosków (a także działania modelu) dla tego samego rozmiaru opon, produkowanego jednak w innych warunkach i okresie.

Dla zbioru I wykonano dodatkowo macierz wykresów punktowych badanych zmiennych wejściowych i zmiennej wyjściowej, którą zaprezentowano na Rysunku 7.18. Każda kolumna i każdy wiersz odpowiada jednej zmiennej (np. `we_br1_width_measured`, `we_1bap_body_avg_off_center`, `wy_con` itd.). Na histogramach umieszczonych po przekątnej rysunku, pokazano rozkłady poszczególnych zmiennych. Poza przekątną widoczne są wykresy punktowe, które ilustrują zależności liniowe między parami zmiennych. Czerwona linia to dopasowana liniowa regresja trendu, która pozwala ocenić kierunek korelacji. Większość zależności wygląda na słabe – chmury punktów są szeroko rozproszone, a linie regresji mają niewielkie nachylenie. Pojawiają się zarówno korelacje dodatnie (linia rosnąca, np. między

we_br1_width_measured a we_br2_width_measured), jak i ujemne (linia malejąca, np. między we_1bap_body_avg_off_center a we_td_width_measured). Niektóre zmienne praktycznie nie wykazują związku (linie poziome, gęsta „chmura” punktów). Widać spory rozrzut – korelacje są raczej słabe, trudno zatem mówić o silnych zależnościach liniowych. Oznacza to, że badane zależności nie są oczywiste i sugeruje to zastosowanie złożonych metod analitycznych w toku badań. Korelacje wybranych zmiennych objaśniających nie pokrywają się pomiędzy sobą, co rokuje korzystnie dla procesu trenowania modelu i uniknięcia jego przeuczenia.




Rysunek 7.18. Macierz wykresów punktowych zmiennych wejściowych i zmiennej wyjściowej zbioru I (opracowanie własne)

Na Rysunkach 7.19. – 7.30. przedstawiono wykresy przebiegu procesu produkcji oraz rozkłady empiryczne wartości pomiarów zmiennych wejściowych, a także zmiennej wyjściowej dla zbioru V. Obserwacja wykresów wskazuje, że wartości pomiarów stożkowatości w tym zbiorze (Rysunki 7.19. i 7.20.) koncentrują się wokół wartości 0

z symetrycznym rozkładem populacji. W porównaniu ze zbiorem I nie występują tu zmienności sygnału w czasie, co świadczy o zdecydowanie większej stabilności procesu zbioru V.




Rysunek 7.19. Wyniki pomiarów stożkowatości dla przebiegu procesu produkcji opon ze zbioru V (opracowanie własne)




Rysunek 7.20. Rozkład empiryczny wartości pomiarów stożkowatości dla zbioru V (opracowanie własne)


Szerokości opasań (Rysunki 7.21., 7.22., 7.25., 7.26.) oraz bieżnika (Rysunki 7.29. i 7.30.) podczas produkcji zachowują się bardzo powtarzalnie. Dochodzi jedynie do sporadycznych przekroczeń limitów zadanych w specyfikacji. Średnie wartości oscylują wokół specyfikacyjnych i rozdział całej populacji jest względem nich symetryczny. Podobnie można skomentować wartości przecentrowania opasań 1 i 2 (Rysunki 7.23., 7.24., 7.27. i 7.28.), gdzie dochodzi jedynie do pojedynczych impulsów przekraczających limity.




Rysunek 7.21. Wyniki pomiarów szerokości opasania 1 dla przebiegu procesu produkcji opon ze zbioru V (opracowanie własne)




Rysunek 7.22. Rozkład empiryczny wartości pomiarów szerokości opasania 1 dla zbioru V (opracowanie własne)




Rysunek 7.23. Wyniki pomiarów przecentrowania opasania 1 dla przebiegu procesu produkcji opon ze zbioru V (opracowanie własne)




Rysunek 7.24. Rozkład empiryczny wartości pomiarów przecentrowania opasania 1 dla zbioru V (opracowanie własne)




Rysunek 7.25. Wyniki pomiarów szerokości opasania 2 dla przebiegu procesu produkcji opon ze zbioru V
(opracowanie własne)




Rysunek 7.26. Rozkład empiryczny wartości pomiarów szerokości opasania 2 dla zbioru V
(opracowanie własne)




Rysunek 7.27. Wyniki pomiarów przecentrowania opasania 2 dla przebiegu procesu produkcji opon ze zbioru V (opracowanie własne)



Rysunek 7.28. Rozkład empiryczny wartości pomiarów przecentrowania opasania 2 dla zbioru V (opracowanie własne)



Rysunek 7.29. Wyniki pomiarów szerokości bieżnika dla przebiegu procesu produkcji opon ze zbioru V (opracowanie własne)



Rysunek 7.30. Rozkład empiryczny wartości pomiarów szerokości bieżnika dla zbioru V (opracowanie własne)

Zachowanie powtarzalności procesu oraz jakości materiałów na poziomie jaki reprezentował zbiór V, poskutkowało całkowitym brakiem odpadów z powodu przekroczenia limitu stożkowatości. Szeroki limit CON tego rozmiaru wynika z tego, że jest on dedykowany na rynek TRADE (wtórny). Ze względu na mniejszy gabaryt tego rozmiaru opon i jego podzespołów, utrzymanie wyników stożkowatości nawet w zakresie $<-20[N]; 15[N]>$ było zdecydowanie łatwiejsze, niż w przypadku rozmiaru ze zbioru I.

Przeprowadzona **eksploracyjna analiza danych** pozwoliła na zrozumienie struktury, właściwości i informacji ukrytych w badanych zbiorach. Wpłynęło to na lepsze poznanie danych, identyfikację trendów, wykrycie anomalii i przygotowanie danych do dalszej analizy oraz działań ukierunkowanych na wybór odpowiedniego modelu dla opisywanego problemu.

7.3 Trenowanie, ewaluacja i wybór modelu

7.3.1 Kryteria doboru mierników do oceny działania badanych modeli

Wybierając najlepszy możliwy model do rozwiązania problemu produkcyjnego stanowiącego przedmiot niniejszej dysertacji, należy wziąć pod uwagę możliwość jego wdrożenia do istniejącej infrastruktury IT. Ważne jest dopasowanie wymaganej mocy obliczeniowej do sprzętu używanego w przedsiębiorstwie. Istotne są również przewidywane koszty wdrożenia. Kluczowym jest zdefiniowanie pojęcia „dokładności” dla każdego indywidualnego przypadku w celu określenia modelu, który będzie najbardziej odpowiedni dla charakteru problemu. Ponadto czas reakcji modelu na podstawie danych otrzymanych online powinien gwarantować płynność przebiegu procesu produkcji.

Dobierając mierniki oceny skuteczności badanych modeli, odniesiono się do różnych typów problemów poruszanych w literaturze, zwracając uwagę na zastosowanie odpowiednich miar ewaluacyjnych dostosowanych do ich specyfiki. Autorzy (Badora i in., 2021) zamierzając przewidywać długość pęknięć zmęczeniowych turbin gazowych, porównali wielokrotną regresję liniową i wielomianową, las losowy, metody kernel-based, AdaBoost, XGBoost i sztuczne sieci neuronowe w kontekście małego zestawu danych (około 30 obserwacji). Okazało się, że model regresji wielomianowej był najlepszym modelem, biorąc pod uwagę wynik walidacji krzyżowej i znormalizowany RMSE oceniony w stosunku do zestawu testowego. Niemniej jednak nie był on wystarczająco wrażliwy na zmiany parametrów wejściowych. Nie doszacował również najdłuższych obserwacji, co było najczęstszą wadą wszystkich utworzonych modeli. Model regresji AdaBoost przewidział te pęknięcia

z najniższym znormalizowanym RMSE. Badanie omawiające kontrolę wymiarową spawanych, tłoczonych ramion stalowych (Kadnár i in., 2023) doprowadziło do podobnych wniosków. Najmniejszy średni bezwzględny błąd procentowy MAPE osiągnięto dla ANN i zauważono, że dokładność modelu wzrastała wraz ze wzrostem rozmiaru zestawu danych treningowych; tymczasem zwiększenie liczby danych ma odwrotny efekt w przypadku regresji liniowej. W (Biyeme i in., 2023) wybrano algorytmy regresji i sieci neuronowe w celu określenia wartości przepływu informacji w modelu łańcucha produkcyjnego. Kryteriami porównawczymi w tym badaniu były MAE, MSE, RMSE i R^2 . Zauważono, że wielkość i charakter produkcji firmy miały znaczący wpływ na wybór czynników oceny do analizy porównawczej. Kolejne badanie zajmujące się podobnym obszarem tematycznym (Rosienkiewicz, 2021) koncentrowało się na hybrydowych modelach prognozowania dla systemów produkcyjnych — konkretnie w odniesieniu do trzech obszarów systemu produkcyjnego: planowania produkcji, konserwacji i kontroli jakości. Potwierdziło ono, że firmy produkcyjne są skłonne wybrać właściwą metodę prognozowania dla swoich konkretnych potrzeb. Ocenę dokładności analizowanych metod prognozowania oparto na średniej R^2 , którą obliczono dla każdego studium przypadku osobno. W innym badaniu, dotyczącym prognozowania niezawodności silników Diesla (Viana i in., 2023), porównano las losowy i MLP. Wybrano RMSE, argumentując że jest on metryką powszechnie stosowaną w procedurze walidacji krzyżowej.

Na podstawie analizy literatury traktującej o budowaniu modeli uczenia maszynowego, wybrano **dwa⁵ mierniki oceny: R^2 i RMSE**. Wyniki uzyskane z modeli, których działanie zweryfikowano w niniejszej pracy doktorskiej porównano i zestawiono ze sobą mając również na względzie wydajność końcowego systemu. Biorąc pod uwagę różne mechanizmy działania metod stosowanych w badaniach, trudno było sprowadzić uzyskane za ich pomocą rezultaty do „wspólnego mianownika”, aby wiarygodnie porównać ich skuteczność (możliwość rozwiązania opisanego problemu). Wybrane mierniki posłużyły do oceny zdolności generalizacyjnych modelu. Zdecydowano, że wybór odpowiedniej metody ML do rozwiązania problemu regresji w tym przypadku, nie powinien być sztywno oparty tylko na jednym mierniku.

⁵ Analizując zastosowanie modelu MLP dodano współczynnik korelacji liniowej r jedynie dla oceny poprawności wytrenowania sieci neuronowych.

7.3.2 Analiza zastosowania regresji liniowej wielu zmiennych

W początkowej fazie badań zastosowano regresję liniową wielu zmiennych jako narzędzie wspomagające potwierdzenie wniosków płynących z eksploracyjnej analizy danych. Jej wykorzystanie było uzasadnione kilkoma względami. Po pierwsze, model ten służy uzyskaniu stosunkowo prostych zależności pomiędzy zmienną objaśnianą a zestawem zmiennych niezależnych, co pozwala na identyfikację potencjalnych predyktorów o istotnym znaczeniu. Po drugie, regresja liniowa pozwala na ocenę kierunku oraz przybliżonej siły związków, co wspiera weryfikację wstępnych hipotez badawczych. Dodatkowo, model liniowy stanowi punkt odniesienia (tzw. model bazowy), względem którego można porównywać efektywność i trafność użytych na późniejszych etapach bardziej złożonych metod. W konsekwencji, wykorzystanie regresji liniowej sprzyja wykrywaniu problemów diagnostycznych, np. współliniowość zmiennych, co z kolei dostarcza informacji niezbędnych do dalszego planowania badań (Puchalski i Warszawa, 2022).

W celu przeprowadzenia analizy z zastosowaniem regresji liniowej wielu zmiennych zastosowano **podział na podzbiory treningowy (70%) i testowy (30%)**, bazując na danych zbiorów I i V. Wyniki aplikacji modelu regresji liniowej wielu zmiennych przedstawiono w Tabeli 7.8.

Tabela 7.8. Wartości RMSE i R^2 dla modelu regresji liniowej wielu zmiennych wykorzystującego dane ze zbiorów I i V (opracowanie własne)


ZBIÓR I		ZBIÓR V	
RMSE	R^2	RMSE	R^2
0.16	0.02	0.14	0.04

Uzyskane wyniki wskazują na bardzo ograniczoną zdolność modelu liniowego do wyjaśniania zmienności w badanych zbiorach danych. W przypadku zbioru I wartość współczynnika determinacji R^2 oznacza, iż model tłumaczy zaledwie 2% całkowitej wariancji, podczas gdy dla zbioru V wynik pozostaje równie niski. Otrzymane rezultaty wskazują, iż regresja liniowa nie jest w stanie odzwierciedlić kluczowych zależności między badanymi zmiennymi. Niska jakość dopasowania oraz obecność niewyjaśnionej zmienności stanowią silne przesłanki do sięgnięcia po bardziej zaawansowane techniki modelowania, umożliwiające badanie związków nieliniowych i interakcji wyższego rzędu, które potencjalnie mogą lepiej oddawać złożoność analizowanego procesu.

7.3.3 Analiza zastosowania modelu MLP

Ze względu na sposób postawienia celu badawczego niniejszej dysertacji, do uzyskania odpowiedzi na pytanie badawcze można użyć perceptronu wielowarstwowego MLP, który jest stosunkowo mało skomplikowaną i szybką metodą uczenia maszynowego. Służy on do budowania modeli przy użyciu oprogramowania naukowego, które są automatycznie optymalizowane w celu uzyskania możliwie najlepszego wyniku pod względem dokładności, minimalizacji RMSE i szybkiego osiągnięcia zbieżności algorytmów (przy jak najkrótszym czasie obliczeń i półautomatycznej opinii podawanej przez modele / system). Należy tutaj także podkreślić jego zdolność do uczenia się nieliniowych modeli niemal w czasie rzeczywistym (nauka online). Perceptron wielowarstwowy reprezentuje algorytm uczenia nadzorowanego, który identyfikuje wzorce poprzez trening na zestawie danych, a jego uniwersalność obejmuje możliwość uczenia się aproksymatora funkcji nieliniowej dla problemów klasyfikacji lub regresji. MLP uczy się na podstawie spadku gradientowego, gdzie gradient obliczany jest za pomocą propagacji wstecznej, następnie klasyfikuje minimalizując funkcję straty, co daje wektor oszacowań prawdopodobieństwa jako wynik. Warto dodać, że charakteryzuje się wszechstronnością zastosowań – z powodzeniem proponowany jest do rozwiązań wspomagających np. utrzymanie tempa produkcji (Mohammadi i in., 2018) i jej ciągłości (Janikova i Bezak, 2016) oraz do prognozowania jakości i efektywności eksploatacji pojazdów samochodowych w systemie usług transportowych (Świdorski i in., 2018).

Dla każdej badanej kombinacji funkcji aktywacji w warstwach ukrytej i wyjściowej testowanie i uczenie sieci oparto na jednej ukrytej warstwie, ponieważ propagacja wsteczna ma wysoką złożoność czasową. W niniejszym badaniu zastosowano algorytm optymalizacyjny *Broydena–Fletcher–Goldfarb–Shanno* (L-BFGS), gdyż zbiega się on szybciej dla mniejszych zestawów danych niż *Stochastic Gradient Descent* (SGD), który wymaga co najmniej 10 000 próbek. Struktura sieci MLP z pięcioma wejściami, różną liczbą neuronów w warstwie ukrytej i jednym wyjściem została przedstawiona na Rysunku 7.31. Liczba neuronów warstwy ukrytej i parametry sieci zostały wybrane eksperymentalnie. Obejmowało to przetestowanie kilkudziesięciu modeli sieci neuronowych MLP z użyciem różnej liczby neuronów w warstwie ukrytej (w zakresie od 6 do 20, ale zwiększenie liczby neuronów nie poprawiło jakości modeli), różnych kombinacji funkcji aktywacji w warstwie ukrytej i wyjściowej oraz różnych czasów uczenia dla tych sieci.



Rysunek 7.31. Struktura sieci MLP opracowana w toku badań z pięcioma wejściami, różną liczbą neuronów w warstwie ukrytej oraz jednym wyjściem (opracowanie własne)


Badania modeli MLP realizowane były z wykorzystaniem danych ze zbiorów I i V, dokonując **podziału na 3 podzbiory: treningowy (70%), walidacyjny (15%) i testowy (15%)**. Pomiedzy warstwami wejściową i wyjściową istnieje jedna warstwa nieliniowa, tzw. warstwa ukryta, która przekształca wartości z warstwy wejściowej za pomocą ważonego sumowania liniowego, po którym następuje nieliniowa funkcja aktywacji (Popescu i in., 2009; Ramchoun i in., 2016). W wyborze funkcji aktywacji zarówno w warstwie ukrytej, jak i w warstwie wyjściowej priorytetem była ich duża elastyczność, ze względu na charakter badanych danych (istotnym było, aby funkcje charakteryzowały się nieliniowością, ciągłością i różniczkowalnością). Dla lepszego zobrazowania przebiegu doboru funkcji aktywacji w toku badań dla warstw ukrytej i wyjściowej, przedstawiono je w Tabeli 7.9. W tej i kolejnych tabelach ujęto tylko te sieci MLP, dla których udało się uzyskać najlepsze rezultaty.

Najlepszą strukturą sieci wykorzystującej perceptron wielowarstwowy do rozwiązania postawionego problemu okazała się sieć MLP 5-8-1, czyli zawierająca 8 neuronów w warstwie ukrytej, z funkcjami aktywacji w warstwie ukrytej będącymi tangensami hiperbolicznymi i warstwą wyjściową z funkcją wykładniczą. Może to wskazywać na znaczną nieliniowość w relacji między zmiennymi wejściowymi i wyjściowymi, a także potwierdza wnioski z przeprowadzonej eksploracyjnej analizy danych.

Tabela 7.9. Funkcje aktywacji w warstwach ukrytej i wyjściowej testowanych sieci MLP
(opracowanie własne)

Struktura sieci	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji w warstwie wyjściowej
MLP 5-9-1	logarytmiczna	tangens hiperboliczny
MLP 5-9-1	tangens hiperboliczny	tangens hiperboliczny
MLP 5-6-1	tangens hiperboliczny	liniowa
MLP 5-9-1	logarytmiczna	liniowa
MLP 5-8-1	tangens hiperboliczny	wykładnicza

Proces uczenia się sieci neuronowej polegał na powtarzaniu wzorców i modyfikowaniu wag do momentu, gdy sieć osiągała satysfakcjonujący rząd wielkości RMSE po nie więcej niż 1000 epok (Rysunek 7.32.).



Rysunek 7.32. Zmiana RMSE podczas uczenia sieci (opracowanie własne)

Jednym z powszechnie stosowanych i możliwych do wyznaczenia dla sieci MLP mierników oceny jest współczynnik korelacji liniowej r (Tabela 7.10. i 7.11.), który umożliwia ocenę stopnia liniowej zależności pomiędzy rzeczywistą wartością zmiennej wyjściowej a jej estymacją dokonaną przez sieć. Dzięki temu możliwe jest nie tylko określenie kierunku, ale także siły związku pomiędzy wartościami przewidywanymi a obserwowanymi, co stanowi cenne uzupełnienie wcześniej wybranych mierników oceny. Przyjmuje on wartości z zakresu $<-1; 1>$, gdzie „1” oznacza doskonałą zgodność. Wartość współczynnika korelacji r bliska 1

nie zawsze jednak oznacza doskonałe dopasowanie – model może przewidywać wartości proporcjonalne, ale przesunięte (np. wszystkie są zaniżone o stałą wartość). Dlatego często dodatkowo stosuje się miary takie jak R^2 , MSE, RMSE czy MAE (Hejmanowski i Witkowski 2015).

Tabela 7.10. Współczynnik korelacji r dla różnych struktur sieci MLP wykorzystujących dane ze zbioru I
(opracowanie własne)

Struktura sieci	Współczynnik korelacji r (trenowanie)	Współczynnik korelacji r (testowanie)	Współczynnik korelacji r (walidacja)
MLP 5-9-1	0.537	0.532	0.570
MLP 5-9-1	0.569	0.542	0.567
MLP 5-6-1	0.522	0.505	0.519
MLP 5-9-1	0.528	0.544	0.568
MLP 5-8-1	0.545	0.550	0.555

Tabela 7.11. Współczynnik korelacji r dla różnych struktur sieci MLP wykorzystujących dane ze zbioru V
(opracowanie własne)

Struktura sieci	Współczynnik korelacji r (trenowanie)	Współczynnik korelacji r (testowanie)	Współczynnik korelacji r (walidacja)
MLP 5-9-1	0.547	0.542	0.560
MLP 5-9-1	0.577	0.551	0.577
MLP 5-6-1	0.529	0.515	0.523
MLP 5-9-1	0.539	0.555	0.580
MLP 5-8-1	0.566	0.573	0.585

Dane wykorzystane w badaniu są wynikami pomiarów – zawierają zatem pewną ilość szumu pomiarowego (dla pomiarowej aparatury elektronicznej nazywanego również „szumem dynamicznym”). W związku z tym współczynnik korelacji obliczony poprawnie dla przypadków treningowych nie powinien być bliski 1 (chyba, że szum jest bardzo słaby). W przypadku bardzo wysokiego r można podejrzewać, że sieć została przeuczona. Takie podejście jest podstawowym sposobem weryfikacji poprawnego działania sieci. Przewidywania przetrenowanej sieci będą miały zawyżony współczynnik korelacji próbie treningowej. W tym przypadku współczynnik korelacji r dla nowych danych podczas treningu był daleki od 1. Dlatego też, przy wyborze sieci należy wziąć pod uwagę jego wartości dla zestawów testowych i walidacyjnych. Niski (ale nie ujemny) współczynnik korelacji niekoniecznie wskazuje na słabą zdolność sieci do rozwiązania narzuconego problemu, ale np. może odzwierciedlać wysoki poziom szumu w danych, z którym sieć radzi sobie

tak dobrze jak jest to możliwe dla danego przypadku. Współczynnik korelacji r , który w tym badaniu oscyluje wokół wartości przedstawionych w Tabelach 7.10 i 7.11 wskazuje, że sieci zostały **prawidłowo wytrenowane**. Wartości współczynnika korelacji r osiągają większą wartość dla zbioru V, co może być związane z większą stabilnością rejestrowanego procesu oraz z występowaniem mniejszej liczby wartości odstających.

Jak już wspomniano, dla wiarygodnej **oceny modeli**, należy w konsekwencji odnieść się do mierników ich oceny. R^2 to procent wariancji zmiennej zależnej wyjaśniony przez zmienne niezależne. R^2 przyjmuje wartości z zakresu $<0; 1>$, gdzie 1 jest wartością najlepiej dopasowaną. W niektórych systemach obliczeniowych R^2 może być ujemne, np. gdy sieć nie odzwierciedla trendu zmian. Wartości R^2 i RMSE dla najlepszych sieci neuronowych MLP uzyskanych w badaniach przedstawiono w Tabeli 7.12.

Tabela 7.12. Wartości RMSE i R^2 dla najlepszych sieci neuronowych MLP uzyskanych w badaniach wykorzystujących dane ze zbiorów I i V (opracowanie własne)

Struktura sieci	ZBIÓR I		ZBIÓR V	
	RMSE	R^2	RMSE	R^2
MLP 5-9-1	1.266	0.298	1.115	0.415
MLP 5-9-1	1.074	0.312	1.032	0.379
MLP 5-6-1	0.411	0.265	0.388	0.335
MLP 5-9-1	0.953	0.298	0.923	0.368
MLP 5-8-1	0.177	0.302	0.158	0.436

Błąd średniokwadratowy RMSE mierzy różnicę między wartościami przewidywanymi przez model a wartościami obserwowanymi w modelowanym środowisku. RMSE jest pierwiastkiem kwadratowym straty kwadratowej przypisującym większą wagę większym różnicom, powszechnie stosowanym w prognozowaniu i analizie regresji w celu weryfikacji wyników eksperymentów. Jest zawsze nieujemny, a im jego wartość jest bliższa 0, tym wyższa jakość modelu. RMSE jest miarą dokładności stosowaną do porównywania błędów przewidywań różnych modeli dla danego zestawu danych, ale nie pomiędzy różnymi zestawami danych, ponieważ zależy od skali (rzędu wielkości). W celu wykorzystania go jako miernika porównującego różne zestawy danych należy zatem zadbać, aby rząd wielkości wartości wykorzystywanych przez model w tych zbiorach był taki sam (jak postąpiono w przedstawionym toku niniejszych badań). Można zatem powiedzieć, że hiperbolizuje on błędy opracowanych modeli.

7.3.4 Analiza zastosowania modeli opartych na drzewach decyzyjnych

Podczas badań opisanych w niniejszym podrozdziale niezmiennie bazowano na zbiorach I i V **podzielonych na 3 podzbiory: treningowy (70%), walidacyjny (15%) i testowy (15%)**. Wykorzystano dwie metody służące do budowania modeli opartych na drzewach decyzyjnych:

1) Modele XGBoost



XGBoost to zaawansowany model z aplikacjami komercyjnymi działającymi w środowiskach Python (Johansson, 2021) i R. Stanowi on rozwiązanie pośrednie wśród metod użytych w niniejszej pracy pod względem dokładności i czasu obliczeń. XGBoost to skalowalny system wzmacniający typu end-to-end, który jest szeroko stosowany w wielu wyzwaniach stawianych przed uczeniem maszynowym. Charakteryzuje się paralelizacją – to znaczy, że wykorzystuje równoległą implementację do uruchomienia sekwencyjnego procesu budowania drzewa. Jest to możliwe dzięki wymiennym cechom pętli używanych do tworzenia „podstawowych komórek” uczących się. Pętla wewnętrzna zlicza cechy, podczas gdy pętla zewnętrzna pozyskuje węzły (powiązania) liści drzewa. Zagnieżdżanie pętli ogranicza paralelizację, ponieważ nie można uruchomić pętli zewnętrznej bez zakończenia pętli wewnętrznej. Równoległe i rozproszone przetwarzanie przyspiesza naukę, co umożliwia szybszą eksplorację modelu. XGBoost posiada również zaimplementowaną regularyzację, czyli rodzaj „kary” nakładanej na model, jeśli w drzewie decyzyjnym jest zbyt wiele końcowych segmentów obserwacji lub liści. Złożoność modelu jest tutaj kontrolowana za pomocą technik *Ridge* i *LASSO*. Ogólna forma modelu XGBoost składa się z dwóch części. Pierwszy składnik – nazywany funkcją straty lub funkcją kosztu – odpowiada za minimalizację błędu. Druga część – regularyzacja – pomaga zapobiegać nadmiernemu dopasowaniu i kontroluje złożoność modelu. XGBoost wykorzystuje dodatkowo metodę walidacji krzyżowej zaimplementowaną w każdej iteracji. Eliminuje to potrzebę rozległego programowania i określania dokładnej liczby iteracji stymulacji potrzebnych do wykonania jednego przebiegu. Ponadto korzysta z innych ulepszeń, np. obliczeń „poza rdzeniem” (*ang. out of core*), które wykorzystują przestrzeń dyskową i obsługują ramki danych nie mieszczące się w pamięci głównej komputera.

Na potrzeby badań przeprowadzonych w niniejszej dysertacji, model XGBoost został wytrenowany dla różnych wartości parametru ‘maximum depth’ (w zakresie 2÷15) – określa on maksymalną głębokość drzewa decyzyjnego w procesie uczenia modelu XGBoost.

Dla obu wykorzystywanych zbiorów danych najlepsze wyniki udało się uzyskać dla maximum depth równego 8 (Tabele 7.13. i 7.14., Rysunki 7.33. i 7.34.).

Tabela 7.13. Wyniki modelu XGBoost uzyskane dla przebadanego zakresu parametru maximum depth z wykorzystaniem danych ze zbioru I (opracowanie własne)


Miernik	Maximum depth											
	2	3	4	5	6	7	8	9	10	11	12	15
RMSE	0.1266	0.1214	0.1209	0.1199	0.1176	0.1156	0.1156	0.1160	0.1159	0.1177	0.1187	0.1225
R²	0.4225	0.4690	0.4730	0.4818	0.4903	0.5014	0.5182	0.5151	0.5161	0.5007	0.4924	0.4588



Rysunek 7.33. Wyniki modelu XGBoost uzyskane dla przebadanego zakresu parametru maximum depth z wykorzystaniem danych ze zbioru I (opracowanie własne)


Tabela 7.14. Wyniki modelu XGBoost uzyskane dla przebadanego zakresu parametru maximum depth z wykorzystaniem danych ze zbioru V (opracowanie własne)

Miernik	Maximum depth											
	2	3	4	5	6	7	8	9	10	11	12	15
RMSE	0.1033	0.1015	0.0998	0.0987	0.0976	0.0949	0.0924	0.0933	0.0941	0.0958	0.0968	0.1002
R ²	0.5977	0.6255	0.6310	0.6423	0.6566	0.6759	0.6811	0.6802	0.6789	0.6711	0.6624	0.6487



Rysunek 7.34. Wyniki modelu XGBoost uzyskane dla przebadanego zakresu parametru maximum depth z wykorzystaniem danych ze zbioru V (opracowanie własne)

Część przykładowego drzewa wygenerowanego przez model XGBoost przedstawiono na Rysunku 7.35.




Rysunek 7.35. Fragment przykładowego drzewa decyzyjnego wygenerowanego przez model XGBoost (opracowanie własne)

Najlepszy model XGBoost dla problemu omawianego w pracy zbudowano przy użyciu hiperparametrów (Chen i Guestrin, 2016) wymienionych poniżej:

- a) `max_depth = 8`.
- b) `learning_rate = 0.1`.
- c) `n_estimators = 1000`.
- d) `objective = "reg:squarederror"`.
- e) `booster = "gbtree"`.

Kluczową zaletą drzew decyzyjnych jest możliwość szybkiego określenia wagi danej cechy w opracowywanym modelu. XGBoost zidentyfikował istotności cech (Rysunek 7.36) wskazując, że czynnikiem mającym największy wpływ na przewidywanie stożkowatości (a w zasadzie na wartość tej wielkości opisującej jednorodność opon) ma szerokość opasania pierwszego (BR1_WIDTH_MEASURED). Wpływ pozostałych zmiennych niezależnych jest o około 30÷45% niższy. Ponadto jego przewagą nad używaną w kolejnym punkcie badań biblioteką ML.NET jest możliwość precyzyjnej analizy przebiegu obliczeń w sposób „krok po kroku” (podobnie jak w przypadku MLP), ze względu na środowisko w którym jest wykorzystywany. Przekłada się to na lepsze zrozumienie zasady działania zbudowanego modelu.



Rysunek 7.36. Istotności cech wyznaczone przy pomocy modelu XGBoost (opracowanie własne)

2) Modele FastTreeRegression i LightGbmRegression

Kolejną metodą, której działanie zostało zweryfikowane w toku badań jest środowisko zautomatyzowanego doboru modelu, oparte na bibliotece ML.NET. Dla pozyskanych danych, rozwiązania można wybierać spośród ponad 120 modeli (czas trenowania: do 1000s). Oferowane modele generują interfejs programowania aplikacji API (*ang. application programming interface*) i kod w języku C# do późniejszego wykorzystania w systemie. Skupiając się na pracy z FastTreeRegression – wydajnej implementacji algorytmu gradientu wzmacniającego o nazwie własnej *Multiple Additive Regression Trees* (MART), podczas badań ustalano wartości następujących przykładowych hiperparametrów:

- a) BIAS: wartość dodana do ważonej sumy wyników wszystkich drzew.
- b) TREES: iteracja RegressionTreeBase (klasa ilości zapętleń) w drzewach.
- c) TreeWeights: waga i-tego RegressionTreeBase (pętli/powtórzenia) w drzewach.

Zmiana tych parametrów prowadzi do zwiększenia efektywności lub wydajności budowanego modelu. Struktura oprogramowania ML.NET wykorzystuje narzędzie AutoML, które wspiera pracę z uczeniem maszynowym poprzez automatyczne wybieranie najlepszych modeli i hiperparametrów dla badanego zestawu danych (automatyczna optymalizacja modelu). Takie rozwiązanie jest przydatne do osiągnięcia wysokich poziomów efektywności modelu i oszczędzania czasu na ręcznym dostrajaniu tworzonych modeli. Po uruchomieniu eksperymentu, przez określony czas AutoML tworzy modele z różnymi kombinacjami algorytmów i hiperparametrów w celu uzyskania najlepszego możliwego wyniku dla wskazanego miernika oceny (proponycja dla każdej takiej kombinacji jest pojedynczą próbą). Jedną z najmocniejszych cech biblioteki jest jej wysoki poziom wydajności – to z pewnością ważne kryterium podczas podejmowaniu decyzji o wyborze narzędzia uczenia maszynowego do zastosowania w środowisku produkcyjnym. Podczas korzystania z ML.NET zaproponowano dwa typy drzew decyzyjnych z gradientem wzmacniającym (GBDT) – LightGbmRegression i FastTreeRegression. Modele te wykorzystują dwie metody (Ke i in., 2017):

- a) Jednostronne próbkowanie gradientowe GOSS (*ang. gradient-based one-side sampling*) – zachowuje wystąpienia o dużych gradientach (tj. większych niż wstępnie zdefiniowany próg) lub wybiera spośród najwyższych percentyli i losowo usuwa tylko wystąpienia o małych gradientach, aby zachować dokładność szacowania wzmocnienia informacji. Jest to związane z faktem, że różne wystąpienia danych odgrywają różne role w obliczaniu wzmocnienia informacji, tj. instancje z większymi

gradientami (instancje niedotrenowane) przyczyniają się w większym stopniu do „zysku informacji”. Skutkuje to dokładniejszym oszacowaniem zysku niż w przypadku zastosowania jednorodnego losowego próbkowania.

- b) Ekskluzywne pakietowanie funkcji EFB (*ang. exclusive feature bundling*) – powoduje bezpieczne łączenie cech wykluczających się w jedną cechę, czyli w tzw. zestaw cech wykluczonych. Złożoność konstrukcji histogramu zmniejsza się, przy czym szybkość struktury trenującej poprawia się bez uszczerbku dla dokładności danych. Wynika to z faktu, że dane wielowymiarowe występują rzadko, co stwarza możliwość niemal bezstratnej (w stosunku do wyniku końcowego) redukcji liczby cech, szczególnie gdy wiele cech wzajemnie się wyklucza.

Na podstawie przeprowadzonych prób (132 próby dla zbioru I i 127 prób dla zbioru V), biblioteka ML.NET wskazała dwa najlepsze modele do rozwiązania opisywanego problemu. Uzyskane dla nich rezultaty wskaźników RMSE i R^2 zaprezentowano w Tabelach 7.15 i 7.16.

Tabela 7.15. Rezultaty dla najlepszych modeli zidentyfikowanych przez bibliotekę ML.NET dla zbioru I
(opracowanie własne)

Numer próby	Model	R^2	RMSE
26	FastTreeRegression	0.7163	0.085
24	LightGbmRegression	0.7070	0.086

Tabela 7.16. Rezultaty dla najlepszych modeli zidentyfikowanych przez bibliotekę ML.NET dla zbioru V
(opracowanie własne)

Numer próby	Model	R^2	RMSE
32	FastTreeRegression	0.7233	0.079
18	LightGbmRegression	0.7150	0.082

7.3.5 Analiza wyników i wybór modelu

Podsumowując dotychczasowy przebieg badań, można stwierdzić, że modelem który osiągnął najlepsze rezultaty był **FastTreeRegression**. Charakteryzował się najniższą średnią wartością RMSE (ocena błędu) oraz najwyższą średnią wartością R^2 (ocena jakości predykcji) dla przebadanych zbiorów danych. W zastosowaniach rzeczywistych (czyli jak dla opisywanego przypadku), wartości R^2 przekraczające wartość 0.7 wskazują

na dużą zgodność pomiędzy wartościami generowanymi przez model a wartościami rzeczywistymi. Przetestowano różne rozwiązania modelowe i żadne z nich nie przyniosło wyższej wartości tego miernika. Oznacza to, że w chcąc poprawić otrzymane rezultaty wymagana jest interwencja w dane, a nie w sam model. R^2 można również zwiększyć poprawiając jakość danych, jest to jednak trudne w systemach czasu rzeczywistego (działających on-line), ponieważ wstępne przetwarzanie i początkowy wybór danych zajmują cenny czas obliczeniowy.

W celu poszukiwania możliwe najlepszego rozwiązania, zdecydowano się na **dodanie odpowiednich zmiennych**, które mogłyby przyczynić się do poprawy wyniku R^2 . Zastosowanie takiego postępowania może pozwolić na wychwycenie większej liczby szumów i losowych fluktuacji w danych – postanowiono zatem podjąć kolejne kroki badawcze w kierunku tej idei.

Kontynuując analizę, **dodano więc kolejną (szóstą) zmienną wejściową**, na którą wybrano PA_WIDTH_MEASURED, czyli średnią wartość pomiaru szerokości zespołu PA dedykowanego do danej opony, zmierzoną przez system prowadzenia karkasu (Rozdział 7.1.1), wyrażoną w [mm]. Na zespół PA składają się boki oraz wykładzina wewnętrzna. Dodatkowe uwzględnienie tej zmiennej wejściowej w modelu, daje wyraźniejszy obraz przesunięcia środka masy opony – w tym momencie model na wejściu zawiera komponenty stanowiące ok. 75% całkowitej masy opony (o konstrukcji standardowej – bez wzmacniającej wkładki runflatowej – czyli takiej, dla której przeprowadzane są badania w niniejszej pracy). Dodanie tej zmiennej jest również uzasadnione fizycznym znaczeniem zjawiska stożkowatości. Tolerancja szerokości PA dla wszystkich produkowanych rozmiarów opon wynosi ± 6 [mm]. Wartości specyfikacyjne szerokości PA dla zbiorów I i V zostały przedstawione w Tabeli 7.17. W Tabeli 7.18. natomiast, zestawiono wyniki obliczeń miar statystycznych dotyczących szerokości PA dla zbiorów I i V.

Tabela 7.17. Wartości specyfikacyjne szerokości PA dla zbiorów I i V (opracowanie własne)


ZMIENNA WEJŚCIOWA	Zbiór I	Zbiór V
PA_WIDTH_MEASURED [mm]	632	624

Tabela 7.18. Miary statystyczne szerokości PA dla zbiorów I i V (opracowanie własne)


Zmienna	Miara	Zbiór I	Zbiór V
PA_WIDTH_MEASURED [mm]	AVG	631.19	623.49
	STDEV	2.53	1.67
	MIN	621.95	615.17
	MAX	639.97	631.69

Na Rysunkach 7.37. – 7.40. przedstawiono wykresy przebiegu procesu produkcji oraz rozkłady empiryczne wartości pomiarów szerokości zespołu PA dla zbiorów I i V.

Dla zbioru I, 2.3% pomiarów przekracza zadane limity specyfikacji. Najwięcej przekroczeń ma miejsce bezpośrednio po wznowieniu produkcji po przestoju wakacyjnym (zakres od próbki nr 3836), co jest widoczne na Rysunku 7.37. Średnia wartość szerokości PA jest jednak bliska specyfikacyjnej i rozkład wartości jest względem niej symetryczny (Rysunek 7.38.).




Rysunek 7.37. Wyniki pomiarów szerokości zespołu PA dla przebiegu procesu produkcji opon ze zbioru I (opracowanie własne)




Rysunek 7.38. Rozkład empiryczny wartości pomiarów szerokości zespołu PA dla zbioru I
(opracowanie własne)

Zbiór V dla nowej zmiennej wykazuje porównywalność i stabilność porównywalną, jak dla zmiennych wejściowych opisywanych poprzednio – występują jedynie pojedyncze przekroczenia zadanej tolerancji (Rysunek 7.39.). Średnia wartość oscyluje wokół specyfikacyjnej i rozdział wszystkich wartości jest względem niej symetryczny (Rysunek 7.40.).



Rysunek 7.39. Wyniki pomiarów szerokości zespołu PA dla przebiegu procesu produkcji opon ze zbioru V
(opracowanie własne)



Rysunek 7.40. Rozkład empiryczny wartości pomiarów szerokości zespołu PA dla zbioru V
(opracowanie własne)

W Tabelach 7.19. i 7.20 porównano rezultaty RMSE i R^2 uzyskane dla wszystkich badanych metod z wykorzystaniem pięciu i sześciu zmiennych wejściowych dla zbioru I i V.

Tabela 7.19. Efekt dodania szerokości PA jako zmiennej wejściowej dla zbioru I (opracowanie własne)

	RMSE		R^2	
	5 zmiennych wejściowych	6 zmiennych wejściowych	5 zmiennych wejściowych	6 zmiennych wejściowych
MLP 5-8-1	0.177	0.156	0.302	0.374
XGBoost	0.116	0.083	0.518	0.719
LightGbmRegression	0.086	0.085	0.707	0.719
FastTreeRegression	0.085	0.084	0.716	0.726

Tabela 7.20. Efekt dodania szerokości PA jako zmiennej wejściowej dla zbioru V (opracowanie własne)

	RMSE		R ²	
	5 zmiennych wejściowych	6 zmiennych wejściowych	5 zmiennych wejściowych	6 zmiennych wejściowych
MLP 5-8-1	0.158	0.141	0.436	0.497
XGBoost	0.092	0.080	0.681	0.742
LightGbmRegression	0.082	0.088	0.715	0.704
FastTreeRegression	0.079	0.086	0.723	0.711

Na podstawie danych uzyskanych z poszczególnych modeli i przedstawionych w Tabelach 7.19. i 7.20 stwierdzono, że **najlepszym rozwiązaniem okazał się model XGBoost**, który charakteryzuje się najniższym RMSE i najwyższą wartością R². Wyniki badań potwierdzają zasadność stosowania uzyskanego modelu w warunkach przemysłowych. Może on potencjalnie przyczynić się do zmniejszenia ilości odpadów opon poprzez wyeliminowanie komponentów, które nie spełniają wymagań jakościowych na wczesnych etapach procesu produkcyjnego, a tym samym znacząco obniżyć koszty produkcji, co jest niezwykle ważne dla nowoczesnych przedsiębiorstw. Godnym zainteresowania jest, że modele oferowane przez bibliotekę ML.NET po dodaniu kolejnej zmiennej obniżyły swoją zdolność predykcji, natomiast wyniki osiągnięte przez model MLP wciąż znacząco odbiegały od możliwości zastosowania go w warunkach rzeczywistej produkcji. Użycie stosunkowo prostej i szybkiej metody XGBoost jest jednym ze sposobów rozwiązania problemu, przy niewielkim wysiłku obliczeniowym i uniknięciu definiowania reguł od podstaw. Może to być istotne w momencie wdrażania nowych rozmiarów opon do produkcji masowej. Ponadto model ten wykazał istotne możliwości poprawy zarówno pod względem funkcjonowania, jak i poprawy uzyskanych wartości mierników oceny. Na tej podstawie, w kolejnym kroku **przystąpiono do walidacji modelu wytrenowanego na zbiorze I** w celu oceny jego zachowania na danych szerszej grupy rozmiarów opon. Założono, że jeśli trening odbywał się na danych charakteryzujących się większym rozrzutem w stosunku do zbioru V, model uzyskany na podstawie nauki na danych zbioru I będzie wykazywał się większą zdolnością do przewidywania wartości odstających (poza zakresowych, czyli poza limitem stożkowatości), co jednocześnie stanowi główny cel jego implementacji.

7.4 Walidacja modelu

W trakcie walidacji opracowanego modelu XGBoost wykorzystano 4 pozostałe zbiory danych, czyli II, III, IV i VI. Celem takiego podejścia jest obiektywne oszacowanie zdolności modelu do generalizacji, czyli jego skuteczności w przewidywaniu wyników dla nowych, nieznanych danych. Walidacja końcowa powinna umożliwić identyfikację ewentualnych problemów i wiarygodności modelu w kontekście jego praktycznego zastosowania. Ostateczne wyniki testowania i walidacji mają fundamentalne znaczenie dla decyzji dotyczących wdrożenia modelu w środowisku produkcyjnym.

Jak już wspomniano, zbiór II dotyczy produkcji tego samego rozmiaru co zbiór I, jednak produkowanego w innym okresie i po zmianie limitów stożkowatości. Ma on posłużyć weryfikacji działania modelu dla tego samego rozmiaru, na którego danych był trenowany. Zbiory III, IV i VI zawierają rejestr produkcji rozmiarów pośrednich gabarytowo pomiędzy rozmiarami zbiorów I i V, różniącymi się również wysokością profilu oraz konstrukcją. Posiadają również większą liczbę rekordów w porównaniu do początkowo wykorzystywanych zbiorów. Dzięki takiemu podejściu, będzie możliwe przeprowadzenie bardziej precyzyjnej oceny działania modelu dla całego zakresu rozmiarów konfekcjonowanych na maszynach VMI MAXX.

W Tabeli 7.21. zaprezentowano wartości specyfikacyjne komponentów niezbędnych do prawidłowej pracy modelu dla zbiorów II, III, IV i VI.

Tabela 7.21. Wartości specyfikacyjne zmiennych wejściowych zbiorów II, III, IV i VI
(opracowanie własne)

ZMIENNA WEJŚCIOWA	Zbiór II	Zbiór III	Zbiór IV	Zbiór VI
BR1_WIDTH_MEASURED [mm]	251	196	191	181
BR2_WIDTH_MEASURED [mm]	241	186	181	171
TD_WIDTH_MEASURED [mm]	308	248	240	222
PA_WIDTH_MEASURED [mm]	632	618	728	580

W Tabeli 7.22. zestawiono wyniki obliczeń następujących miar statystycznych: wartość średnia (AVG), odchylenie standardowe (STDEV), wartości maksymalna (MAX) i minimalna (MIN) badanych zmiennych wejściowych i zmiennej wyjściowej dla wymienionych zbiorów.

Tabela 7.22. Miary statystyczne zmiennych wejściowych zbiorów II, III, IV i VI (opracowanie własne)

Zmienna	Miara	Zbiór II	Zbiór III	Zbiór IV	Zbiór VI
BR1_WIDTH_MEASURED [mm]	AVG	250.95	196.62	191.23	181.95
	STDEV	1.04	0.93	0.97	0.80
	MIN	247.79	192.55	187.21	175.49
	MAX	254.61	199.07	193.73	184.06
BR2_WIDTH_MEASURED [mm]	AVG	240.87	185.85	180.88	171.61
	STDEV	1.04	0.82	1.02	0.85
	MIN	234.50	182.03	173.57	166.53
	MAX	244.40	188.51	184.27	173.88
TD_WIDTH_MEASURED [mm]	AVG	306.71	249.11	242.32	222.23
	STDEV	1.19	0.95	1.11	0.78
	MIN	302.20	245.53	233.79	218.47
	MAX	311.02	252.80	246.41	225.58
1BAP_BODY_AVG_OFF_CENTER [mm]	AVG	0.15	0.63	-0.85	0.00
	STDEV	0.13	0.27	0.24	0.14
	MIN	-1.72	-0.02	-2.42	-0.44
	MAX	1.09	2.24	-0.11	0.59
2BAP_BODY_AVG_OFF_CENTER [mm]	AVG	0.04	0.73	-0.88	0.12
	STDEV	0.34	0.12	0.72	0.11
	MIN	-3.71	0.30	-3.83	-0.24
	MAX	0.97	1.85	1.51	0.43
PA_WIDTH_MEASURED [mm]	AVG	631.32	618.83	727.18	580.84
	STDEV	2.10	1.52	1.80	1.54
	MIN	623.07	613.04	716.25	572.93
	MAX	639.43	625.21	735.49	589.21
Stożkowatość (CON) [N]	AVG	0.93	4.70	-7.93	-2.51
	STDEV	14.21	6.96	17.30	4.53
	MIN	-66.00	-25.00	-88.00	-24.00
	MAX	116.00	31.00	68.00	27.00

Zbiory danych używane do walidacji opracowanego modelu przygotowano w taki sam sposób, jak przeprowadzono to dla wcześniej przygotowywanych danych, co opisane zostało w Rozdziale 7.2.1. Zastosowano również ten sam podział danych na trzy podzbiory: treningowy (70%), walidacyjny (15%) i testowy (15%). W tym postępowaniu uzyskano wyniki RMSE i R^2 , które zestawiono w Tabeli 7.23.

Tabela 7.23. Wyniki RMSE i R^2 uzyskane podczas walidacji modelu XGBoost (opracowanie własne)

Miernik	Zbiór II	Zbiór III	Zbiór IV	Zbiór VI
RMSE	0.085	0.078	0.081	0.071
R^2	0.725	0.746	0.732	0.751

Etap walidacji był przeprowadzany ze świadomością, że zwiększenie liczby próbek powyżej 10 000 może wymagać ponownego dostrojenia modelu lub nawet modyfikacji użytego algorytmu (Longwic i in., 2012). Zmiany hiperparametrów używanego modelu w czasie testowania go na nowych zbiorach danych nie przyniosły już jednak dalszej poprawy wyników stosowanych miar porównawczych. Model XGBoost został zatem finalnie wybrany do wdrożenia w przedsiębiorstwie – uzyskał najlepszy wynik po dodaniu zmiennej wejściowej od zespołu PA i wykazał najlepszą średnią wyników mierników oceny dla wszystkich przebadanych rozmiarów opon, co dodatkowo wskazuje na jego uniwersalność. Wnioskując na podstawie uzyskanych rezultatów przyjmuje się jednak możliwość, że dla różnych grup rozmiarów w przyszłości mogą zostać zastosowane różne modele, ze względu na zmienność zbiorów danych – o czym świadczy m.in. różnica wartości charakteryzującego je odchylenia standardowego.

W niniejszych badaniach warto zwrócić uwagę na kluczowy problem: tradycyjne metody regresji – zarówno liniowe (np. regresja liniowa, Lasso, ridge) – jak i nieliniowe (np. Support Vector Regression, drzewa decyzyjne) mają swoje ograniczenia w modelowaniu funkcji nieliniowych. Liniowe modele bywają zbyt uproszczone, SVR wymaga kosztownego doboru jądra i czasu obliczeniowego, natomiast drzewa decyzyjne bywają niestabilne (Chen i in., 2020). Przed wdrożeniem wymagana jest weryfikacja, czy drzewa decyzyjne mogą efektywnie aproksymować funkcje nieliniowe i przewidywać realne dane. Jest to istotne, ponieważ w środowisku produkcyjnym istnieje wysokie prawdopodobieństwo wystąpienia wejściowych wartości poza zakresowych. Ponadto, głównym zadaniem implementowanego modelu jest predykcja odstających wartości stożkowatości, na których wystąpienie model musi reagować w prawidłowy sposób. Podstawą do osiągnięcia tego celu jest odpowiednie

zbalansowanie głębokości drzewa. Nadmierna albo zbyt mała głębokość mogłyby prowadzić do dużego błędu predykcji. Dlatego też model XGBoost został przebadany w szerokim zakresie parametru głębokości drzewa 'max_depth'.

Należy zauważyć, że odpowiedni dobór danych treningowych (tj. zestawów parametrów wejściowych i wyjściowych) ułatwił identyfikację nieoczywistych, nieznanych lub wcześniej niekompletnych reguł, a tym samym uzupełnił ich opis matematyczny i możliwą analizę innymi metodami. Może to być przydatne w przypadku pojawienia się niezweryfikowanych baz danych, nowo wdrożonych maszyn (pracujących nawet na wcześniejszym etapie produkcji opon, niż konfekcja) lub rozmiarów opon, które nie były jeszcze analizowane metodami obliczeniowymi.

Dodatkową zaletą modelu, która sprawia, że nadaje się do wykorzystania w masowej produkcji opon, jest jego natychmiastowa reakcja na wartości zmiennych wejściowych (poza zakresem tolerancji). Pozwala to na przewidywanie i ocenę jakości produkcji w trybie ciągłym (Bai i in., 2017). Ta cecha może ułatwić natychmiastowe wycofanie partii wadliwych komponentów opon (minimalizacja strat materiałowych) i ograniczyć ilość powstawania złomu obiegowego (Kosmela i in., 2021) w przedsiębiorstwie. Przyspieszy to również ustalanie przyczyn źródłowych usterek / błędów powstających w procesie produkcyjnym (eliminacja strat czasu), co stanowi jeden z głównych czynników wpływającym na utrzymanie ciągłości produkcji opon (Krishnan i in., 2018). Gwarantowana szybkość reakcji, poprawi zdolność krótkoterminowego planowania oraz elastyczność produkcyjną firmy (Krynke, 2021), co stanowi jedno z głównych założeń Przemysłu 4.0. W rezultacie możliwa jest terminowa modyfikacja ustawień maszyny, co zatrzyma przepływ wadliwego produktu do kolejnych etapów procesu produkcyjnego (eliminacja złomu) (Kim i in., 2019). Należy w tym miejscu również podkreślić pozytywny wpływ na aspekty środowiskowe, ponieważ odpady gumowe które są wykorzystywane jako paliwo alternatywne (odzysk energii), odpowiadają za 6% globalnej emisji CO₂ (Skrzyniarz, 2020). Ma to tym większe znaczenie w przypadku opon wyrzucanych bezpośrednio po procesie produkcyjnym, które nigdy nie trafiają do normalnej eksploatacji, co stanowi poważne marnotrawstwo (Skarbek-Żabkin i Kamińska, 2015).

8. Część wdrożeniowa


Głównym celem niniejszej pracy doktorskiej było opracowanie modelu przewidującego w czasie rzeczywistym wyniki stożkowatości opon na określonym poziomie, na podstawie danych wejściowych z procesu konfekcji. Kolejnym etapem jest wdrożenie opracowanego modelu uczenia maszynowego, jako narzędzia wspomagającego masową produkcję opon radialnych w przedsiębiorstwie. W niniejszym rozdziale zostanie przedstawiony efekt wdrożenia modelu do systemu informatycznego przedsiębiorstwa oraz maszyn VMI MAXX. Zostaną również omówione perspektywy rozwoju tego narzędzia w przedsiębiorstwie.

8.1 Implementacja modelu do systemu informatycznego przedsiębiorstwa oraz maszyn VMI MAXX

Dla poprawnego działania modelu w środowisku produkcyjnym przeprowadzono już następujące działania w kierunku implementacji modelu do systemu informatycznego:

- 1) Zwiększono częstotliwość kalibracji aparatury pomiarowej, czyli CCMO (monitora karkasu) oraz BTMO (monitora bębna B&T). Dotychczas realizowana była raz do roku, obecnie interwał kalibracji ustalono na 6 miesięcy.
- 2) Wyrównano wygląd interfejsu CORTEXX wszystkich maszyn VMI MAXX w fabryce. Dodano przy tym konieczność zapisu newralgicznych zmiennych wejściowych, niezbędnych do prawidłowej pracy modelu. W Bazie Danych Produkcyjnych maszyny VMI MAXX uwzględniono również dopisywanie ustalonych limitów stożkowatości dla każdego rozmiaru opon w celu ich konsolidacji z wynikiem wygenerowanym przez model i w konsekwencji wyświetleniem prawidłowego komunikatu.
- 3) Utworzono bazę danych integrującą dane wejściowe i wyjściowe w celu ciągłego douczania algorytmu. Dane wejściowe są automatycznie odpowiednio przetwarzane (przygotowywane w analogiczny sposób, jak miało to miejsce w toku badań) do wymaganego formatu i zasilają model. Dane wyjściowe służą weryfikacji poprawności działania po pomiarze jednorodności.


Nowy schemat rejestracji i przepływu danych został przedstawiony na Rysunku 8.1.



Rysunek 8.1. Schemat rejestracji i przygotowania danych na tle procesu produkcji opon po wdrożeniu modelu (opracowanie własne)

Zmiany na maszynach VMI MAXX po wdrożeniu modelu:

- 1) Pomiary wymiarów opasań, bieżnika i PA są wysyłane on-line do zintegrowanej bazy danych, przygotowywane i przetwarzane przez model. Model dokonuje predykcji wartości stożkowatości.
- 2) Rezultatem wdrożenia płynącego z niniejszej pracy doktorskiej jest pojawienie się komunikatu „con out of tolerance” widocznego na Rysunku 8.2. Wyświetla się on tylko i wyłącznie w przypadku, kiedy model przetworzy istotne dla jego działania zmienne wejściowe oraz zidentyfikuje je jako potencjalną przyczynę przekroczenia limitu stożkowatości (informacja zwrotna – predykcja przekroczenia limitu stożkowatości).



Rysunek 8.2. Komunikat wywołany działaniem modelu (opracowanie własne)

- 3) Już w tym momencie możliwe jest zareagowanie na otrzymaną informację. Poszukując przyczyny wystąpienia komunikatu, na podstawie pomiarów wykonanych przez maszynę można rozpocząć od sprawdzenia, czy wymiar któregoś z materiałów, którego dane zasilają model przekroczył swoją tolerancję. Należy wziąć pod uwagę

wyznaczoną przez model XGBoost istotność cech, którą można bezpośrednio przełożyć na kolejność podejmowanych kroków podczas poszukiwania przyczyny źródłowej problemu (rozpoczynając od materiału mającego największy wpływ na wynik generowany przez model).

- 4) W celu potwierdzenia przypuszczeń, można przygotować nowy odcinek newralgicznego materiału (jeśli odnaleziono przekroczenie dotyczące materiału opasań, bieżnika lub PA). Maszyna przeprowadza pomiar i nałożenie kolejnego odcinka. Dane wejściowe od uzupełnianego materiału zostają zestawiane z danymi materiałów aktualnie znajdującymi się na maszynie i czekającymi na użycie do bieżącej sztuki opony. Dochodzi do interpretacji aktualnej sytuacji przez model.

Przedstawione powyżej funkcjonalności i osiągnięte dotychczas rezultaty wdrożenia stanowią część większego projektu, co zostanie scharakteryzowane w kolejnym podrozdziale.

8.2 Monitorowanie i utrzymanie modelu oraz potencjalne efekty wdrożenia

Wdrażane rozwiązanie wymaga ustalenia kilku kwestii wewnątrz przedsiębiorstwa:

- 1) Działania zaprezentowane w Rozdziale 8.1. realizowane są na razie tylko na najnowszej maszynie VMI MAXX nr X08, ze względu na jej obecny status „testowy” (pracuje jedynie na potrzeby prób i przeprowadzania badań). Dało to możliwość realizacji działań związanych z niniejszą dysertacją bez zakłócania planu produkcji przedsiębiorstwa. Produkcja masowa na tej maszynie wystartuje jednak dopiero w drugiej połowie 2026 (aktualna prognoza).
- 2) Biorąc pod uwagę sposób działania modelu opisany w Rozdziale 8.1, należy opracować standard postępowania z wadliwym materiałem na szpuli / wózku. Wycofanie materiału na pewno będzie wymagało wykonania większej liczby pomiarów – do dyspozycji nie będzie mogło dojść na podstawie tylko jednego odcinka komponentu dedykowanego do 1 sztuki opony.
- 3) Identyfikacja odpadów spowodowanych stożkowatością już na poziomie pomiarów materiałowych eliminuje powstawanie wadliwych opon surowych. Dzięki pojawiającemu się komunikatowi, konfekcja wadliwej opony zostaje zatrzymana.

- 4) W roku 2024 z powodu przekroczenia limitu CON przeróbkom musiało ulec 6000szt. opon wyprodukowanych tylko przez maszyny VMI MAXX. Przyjmuje się, że wymagany poziom prawidłowych przewidzeń wdrożonego narzędzia to 70% - o tyle zatem powinien spaść poziom przeróbek / złomów opon z przyczyny przekroczenia limitu stożkowatości w masowej produkcji opon. Potwierdziło się to już podczas prób wdrażania nowych rozmiarów opon realizowanych na maszynie nr X08. W trakcie produkcji próbnej zliczano pojawiające się komunikaty i zestawiono ich liczbę z faktycznymi przekroczeniami limitu stożkowatości opon próbnych. Dotyczyło to różnych rozmiarów opon o różnej konstrukcji, dla których realizowane były próby wdrożeniowe.
- 5) Zgodnie ze wstępnymi założeniami, do weryfikacji poprawności działania modelu w trakcie masowej produkcji opon będzie dochodziło w następujący sposób:
 - a) 10 opon zidentyfikowanych przez zaimplementowane narzędzie jako potencjalne złomy (a dokładnie: zawierające w sobie wadliwy komponent), będzie należało zwulkanizować i dedykować do pomiaru jednorodności.
 - b) Jeśli mniej niż 7 opon przekroczy limit CON, będzie musiało dojść do korekty hiperparametrów / wywołania manualnego douczania algorytmu.
 - c) Częstotliwość powyższej weryfikacji pozostaje jeszcze kwestią otwartą.
- 6) Wdrożone rozwiązanie ulegnie faktycznej weryfikacji dopiero po rozpoczęciu regularnej produkcji na maszynie nr X08. Wtedy też implementacja tego rozwiązania zostanie rozszerzona na pozostałe maszyny VMI MAXX. Będzie można wówczas w sposób bardziej precyzyjny określić realny wpływ narzędzia na poziom złomów oraz ocenić jego faktyczny poziom predykcji. Dotyczy to także podejścia do tolerancji wymiarowych używanych materiałów – narzędzie utrzymujące poziom przewidzeń na określonym poziomie, będzie można dopuścić pewne (określone wewnętrznymi restrykcjami / zakresami) odstępstwa, jeśli np. przekroczenia centrowania opasań 1 i 2 skompensują się i według modelu zaowocują rezultatem pomiaru stożkowatości zawartym w limicie.
- 7) Można stwierdzić, że przy modelach wytrenowanych na zebranych danych i wymaganych progu dokładności szacowania ustalonym na podstawie bieżących błędów, rozwiązania oparte na sztucznej inteligencji mogą generować nieprawidłowe rozpoznania (dobrych produktów jako wadliwych i odwrotnie). W przypadku

wątpliwości konieczna będzie decyzja (ekspercka) człowieka, podejmowana w procesie kontroli technicznej.

- 8) Dodatkową zaletą maszyny nr X08 w stosunku do pozostałych maszyn, jest jej zdolność do przeprowadzania pomiaru przecentrowania materiału bieżnika. Istnieją uzasadnione przypuszczenia (przeprowadzone dotychczas badania, fizyczny sens zjawiska ściągania pojazdów), że dodanie tego pomiaru do danych wejściowych modelu może istotnie poprawić jakość jego predykcji.
- 9) Sposób działania wdrożonego rozwiązania można replikować do innych fabryk produkujących opony, przy założeniu, że pomiary komponentów niezbędne do prawidłowej pracy algorytmu w toku produkcji będą realizowane i rejestrowane, z kolei lokalna infrastruktura informatyczna będzie w stanie zasilać model. Może ono być także stosowane przez producentów maszyn konfekcyjnych, tj. VMI GROUP.

Powyższe stwierdzenia można podsumować jako kolejny z aspektów rozwoju przemysłu oponiarskiego, który nakreśla niedaleką przyszłość fabryki Bridgestone Poznań.

9. Wnioski

1) Wnioski poznawcze

- a) Przyjęte w toku badań zmienne wejściowe, będące wynikami pomiarów wymiarowych materiałów składowych opony na etapie konfekcji, pozwoliły na skuteczną predykcję stożkowatości opon przy zastosowaniu modelu uczenia maszynowego. Dobór danych wejściowych był również zgodny z fizycznym sensem zjawiska stożkowatości opon. Położenie materiałów i rozkład ich masy względem osi symetrii opony ma zatem bezpośredni wpływ na powstawanie efektu stożka.
- b) Na podstawie wykonanej eksploracyjnej analizy danych oraz przeprowadzonej również regresji liniowej wielu zmiennych można stwierdzić, iż badane zależności pomiędzy zmiennymi wejściowymi a zmienną wyjściową mają charakter nieliniowy.
- c) Najlepszym rozwiązaniem okazał się model XGBoost, charakteryzujący się najniższym RMSE i najwyższą wartością R^2 , gwarantującym co najmniej 70% poprawnych przewidywań, co można stwierdzić na podstawie wyników badań oraz przeprowadzonych po jego implementacji prób wdrożeniowych nowych rozmiarów opon.
- d) Modele FastTreeRegression i LightGbmRegression po dodaniu kolejnej (szóstej) zmiennej wejściowej, obniżyły swoją jakość predykcji, co więcej poziom osiągnięty przez model MLP wciąż znacząco wówczas odbiegał od możliwości zastosowania go w warunkach rzeczywistej produkcji.
- e) Opracowany model XGBoost potrafi generować w czasie rzeczywistym wartości stożkowatości opon na podstawie zasilających go danych wejściowych z procesu ich konfekcji – cel badawczy pracy został zatem osiągnięty.
- f) Na podstawie przedstawionego w części wdrożeniowej przykładu działania modelu można stwierdzić, że na etapie pomiaru zmiennych wejściowych komponentów składowych danej opony podczas procesu konfekcji możliwa jest skuteczna predykcja jej stożkowatości. Potwierdza to hipotezę badawczą postawioną w niniejszej rozprawie doktorskiej.
- g) Jakość uzyskiwanych wyników predykcji może być zakłócana poprzez wpływ pozostałych etapów procesu produkcji opon, które odbywają się pomiędzy pomiarami wielkości wejściowych i wyjściowych modelu.

2) **Wnioski użyteczne**

- a) Uzyskane wyniki i przebieg wdrożenia wskazują na możliwość zastosowania otrzymanego modelu w warunkach przemysłowych.
- b) Wykorzystanie modelu opartego na SNN do bezpośredniej identyfikacji wadliwości parametrów / cech w oponach dla rzeczywistych danych testowych (z kontroli technicznej) jest możliwe.
- c) Uzyskane rezultaty oraz dane zbierane w czasie rzeczywistym dają możliwość szybkiego reagowania, np. poprzez natychmiastowe wycofanie z użycia materiału będącego powodem powstawania defektów lub wprowadzenie korekty do procesu, co ma znaczący wpływ na obniżenie kosztów produkcji (eliminacja straty czasu, minimalizacja strat materiałowych, zmniejszenie liczby złomów opon).
- d) Zastosowanie opisywanego modelu wpłynie na zwiększenie elastyczności krótkoterminowego planowania produkcji materiałów i opon dzięki szybkiej informacji zwrotnej o zaistnieniu wadliwych prefabrykatów. Jest to tym bardziej kluczowe podczas realizacji krótkich partii produkcyjnych, wymuszających częste zmiany rozmiaru na maszynach konfekcjonujących opony i przygotowujących materiały.
- e) Identyfikacja odpadów spowodowanych stożkowatością już na poziomie pomiarów materiałowych i dzięki możliwości wstrzymania procesu konfekcji, eliminuje powstawanie wadliwych opon surowych (które w domyśle po procesie wulkanizacji nie zawierałyby się w limicie CON). Zmniejszenie ilości odpadów opon poprzez wyeliminowanie komponentów, które nie spełniają wymagań jakościowych na wczesnych etapach procesu produkcyjnego obniży jego koszty, co jest niezwykle ważne dla współczesnego przedsiębiorstwa.
- f) Wdrożone narzędzie zapewnia kontrolę jakości produkcji on-line, co wspiera koncepcję Przemysłu 4.0. Przyczynia się to również do wytwarzania produktów bardziej przewidywalnych w eksploatacji.
- g) Poprawie ulegnie również utrzymanie ciągłości produkcji, dzięki przyspieszeniu ustalania przyczyn źródłowych usterek / błędów powstających w procesie produkcyjnym za pomocą sugestii z interfejsu maszyny VMI MAXX po pojawiającym się komunikacie o możliwym przekroczeniu limitu stożkowatości. Wniosek ten dodatkowo poparty jest wyznaczoną przez model XGBoost istotnością cech, którą można przełożyć na kolejność podejmowanych kroków podczas poszukiwania przyczyny źródłowej problemu (rozpoczynając od materiału mającego największy wpływ na wynik generowany przez model).

- h) Problem rozwiązany poprzez model opracowany podczas prac realizowanych na potrzeby niniejszej rozprawy doktorskiej pozwala na bieżące korygowanie procesu produkcji, co w praktyce przekłada się na ograniczenie liczby odpadów, redukcję kosztów oraz podniesienie jakości wyrobów. Efekty te mają istotne znaczenie dla rozwoju metod stosowanych w inżynierii mechanicznej, a w szczególności w obszarze inżynierii produkcji i wpisują się w ideę Przemysłu 4.0, dążącą do zwiększenia efektywności i konkurencyjności przedsiębiorstw.

3) Wnioski do dalszych badań

- a) Zbudowany model pozwoli na powtórny weryfikację stosowanych obecnie standardów i tolerancji procesu produkcji opon – wpłynie on na bardziej precyzyjne dopasowanie jakości wyrobów do faktycznych potrzeb klienta. Po weryfikacji w masowej produkcji, narzędzie utrzymujące poziom predykcji na wypracowanym poziomie, będzie mogło dopuścić pewne (określone wewnętrznymi restrykcjami) odstępstwa od narzuconych w standardach tolerancji, jeśli np. przekroczenia centrowania opasań 1 i 2 skompensują się i według modelu zaowocują rezultatem pomiaru stożkowatości zawartym w limicie.
- b) Douczanie algorytmów w oparciu o aktualne dane oraz określenie wymaganego progu dokładności oszacowania na podstawie obecnych błędów jest niezbędne, aby rozwiązania oparte na sztucznej inteligencji przełożyły się na zmniejszenie liczby błędnych rozpoznań (produktów dobrych jako wadliwych i odwrotnie). W części sytuacji (wątpliwych) o wynikach kontroli technicznej będzie musiał decydować człowiek.
- c) Rozwiązanie będące przedmiotem przeprowadzonych badań może być potencjalnie wdrożone w każdej firmie produkującej opony radialne do samochodów osobowych pod warunkiem, że ma ona możliwość rejestrowania zmiennych wejściowych i wyjściowych istotnych dla działania modelu.
- d) Przeprowadzone badania stanowią (w zakresie ograniczonym przez zmienne / cechy wejściowe i wyjściowe) cyfrowy model opony, który może być używany jako podstawa do cyfrowego rozpoznawania dobrej opony i opony złomowanej, a także zmian prowadzących do naturalnego lub przedwczesnego zużycia opony. Takie modele można budować, wykorzystując proces automatycznego ładowania danych w ramach Przemysłowego Internetu Rzeczy (IIoT). W ten sposób można testować przyszłe modyfikacje bez konieczności przełączania, np. całej linii produkcyjnej.

- e) Użycie stosunkowo prostej i szybkiej metody XGBoost stanowi sposób rozwiązania problemu przy niewielkim wysiłku obliczeniowym i uniknięciu definiowania reguł od podstaw. Może to być istotne w momencie wdrażania nowych rozmiarów opon do produkcji masowej.
- f) Istnieją przesłanki badawcze (przeprowadzone dotychczas badania, fizyczny sens zjawiska ściągania pojazdów), że dodanie pomiaru przecentrowania materiału bieżnika do danych wejściowych modelu może istotnie poprawić poziom jego predykcji, co może być zweryfikowane tylko na maszynie nr X08.
- g) Opracowane rozwiązanie może zostać zastosowane przez producentów maszyn konfekcyjnych, tj. VMI GROUP.

Literatura

- 1) Al-jabery Khalid K. et al. (2020), Data preprocessing. Computational Learning Approaches to Data Analytics in Biomedical Applications, <https://doi.org/10.1016/C2016-0-04633-8>.
- 2) Al'Aref S.J. et al. (2019), Clinical applications of machine learning in cardiovascular disease and its relevance to cardiac imagin,. European Heart Journal, 40(24), pp. 1975–1986, doi:10.1093/eurheartj/ehy404.
- 3) Angrick C., van Putten S., and Prokop G. (2014), Influence of Tire Core and Surface Temperature on Lateral Tire Characteristics, SAE Int. J. Passeng. Cars - Mech. Syst. 7(2):2014, doi:10.4271/2014-01-0074.
- 4) Antunes Rodrigues J., Torres Farinha J., Mendes M., Mateus R. i Marques Cardoso A. (2022), Short and long forecast to implement predictive maintenance in a pulp industry, Eksploatacja i Niezawodność – Maintenance and Reliability, 24(1), 33–41, <https://doi.org/10.17531/ein.2022.1.5>.
- 5) Arat, M., Singh, K. and Taheri, S. (2013), Optimal Tire Force Allocation by Means of Smart Tire Technology, SAE Int. J. Passeng. Cars - Mech. Syst. 6(1):2013, doi:10.4271/2013-01-0694.
- 6) "Auto Bild, Ranking opon całorocznych do SUV-ów. Pod lupą 235/65 R17, <https://www.auto-swiat.pl/porady/eksploatacja/przetestowalismy-10-opon-calorocznych-do-suv-ow-najpopularniejszy-rozmiar-duze/gvez3rm> (30.09.2024).
- 7) Badora M., Sepe M., Bielecki M., Graziano A., Szolc T. (2021), Predicting length of fatigue cracks by means of machine learning algorithms in the small-data regime, Eksploatacja i Niezawodność – Maintenance and Reliability, 2021;23(3):575-585. <https://doi.org/10.17531/ein.2021.3.19>.
- 8) Bai Y., Li C., Sun Z. and Chen H. (2017), Deep neural network for manufacturing quality prediction, 2017 Prognostics and System Health Management Conference (PHM-Harbin), Harbin, China, pp. 1-5, doi: 10.1109/PHM.2017.8079165.
- 9) Baillie M., Le Cessie S., Schmidt C.A., Lusa L., Huebner M. (2022), Ten simple rules for initial data analysis, PLOS Computational Biology, 18 (2): e1009819, doi:10.1371/journal.pcbi.1009819.

- 10) Barbosa B. H. G., Xu N., Askari H. and Khajepour A. (2022), Lateral Force Prediction Using Gaussian Process Regression for Intelligent Tire Systems, *IEEE Transactions on Systems, Man and Cybernetics: Systems*; 2022, vol. 52, no. 8, pp. 5332-5343, doi: 10.1109/TSMC.2021.3123310.
- 11) Bastiaan J.M. (2018), Physical Validation Testing of a Smart Tire Prototype for Estimation of Tire Forces, *SAE Technical Paper 2018-01-1117*, doi:10.4271/2018-01-1117.
- 12) Beauchamp G., Pentecost D., Koch D. and Rose, N. (2016b), The Relationship Between Tire Mark Striations and Tire Forces, *SAE Int. J. Trans. Safety* 4(1):2016, doi:10.4271/2016-01-1479.
- 13) Beauchamp G., Thornton D., Bortles W. and Rose N. (2016a), Tire Mark Striations: Sensitivity and Uncertainty Analysis, *SAE Int. J. Trans. Safety* 4(1):2016, doi:10.4271/2016-01-1468.
- 14) Bęczkowska S., Korzeb J., Koziak S., Weyssenhoff A. (2018), Niejednorodność i wady materiałowe opon samochodów osobowych – zagadnienia wybrane, *Prace Naukowe Politechniki Warszawskiej, Transport*, z. 121, s.9–20.
- 15) Bishop Ch.M. (2006), *Pattern Recognition and Machine Learning*, ISBN-10: 0-387-31073-8.
- 16) Biyeme F., Mbakop A. M., Chana A. M., Voufo J., Meva'a J. R. L. (2023), An analytical model for analyzing the value of information flow in the production chain model using regression algorithms and neural networks, *Supply Chain Analytics*, Vol. 2, doi.org/10.1016/j.sca.2023.100013.
- 17) Boada M.J.L., Boada B.L., Garcia-Pozuelo D., Diaz V. (2009), Application of Neural Networks for Estimation of Tyre/Road Forces, In *Proceedings of the Volume 10: Mechanical Systems and Control, Parts A and B*, Lake Buena Vista, FL, USA, 13–19 November 2009; ASME: New York, NY, USA; pp. 427–433.
- 18) Breiman L. (1984), *Classification and Regression Trees* (1st ed.), Routledge, <https://doi.org/10.1201/9781315139470>.
- 19) Bridgestone Europe Completes Acquisition of TomTom Telematics, <https://www.businesswire.com/news/home/20190401005461/en/Bridgestone-Europe-Completes-Acquisition-of-TomTom-Telematics> (dostęp: 11.12.2024).

- 20) Brownlee, J. (2016) Simple linear regression tutorial for machine learning, <https://machinelearningmastery.com/simple-linear-regression-tutorial-for-machine-learning/> (dostęp: 18 maja 2025).
- 21) Brusoni S., Cassi L. & Tuna S. (2021), Knowledge integration between technical change and strategy making, *J. Evol .Econ.* 31, 1521–1552, <https://doi.org/10.1007/s00191-020-00706-3>.
- 22) Bujak Ł. (2008), *Drzewa Decyzyjne*, Toruń, Wyd. UMK
- 23) Bukowski M., k-NN, https://rpubs.com/M_B/metody6 (dostęp 02.05.2025).
- 24) Burkov, A. (2019) *The Hundred-Page Machine Learning Book*. Québec: Andriy Burkov Publishing. ISBN 978-1999579500.
- 25) Cao R. and Bolton J. (2015), Improved Model for Coupled Structural-Acoustic Modes of Tires, *SAE Int. J. Passeng. Cars - Mech. Syst.* 8(3):2015, doi:10.4271/2015-01-2199.
- 26) Chen C. and Yan X. (2015), Optimization of a Multilayer Neural Network by Using Minimal Redundancy Maximal Relevance-Partial Mutual Information Clustering With Least Square Regression, *IEEE Transactions on Neural Networks and Learning Systems*, 26(6), pp.1177–1190, <https://doi.org/10.1109/TNNLS.2014.2330900>.
- 27) Chen D. et al. (2020), Deep Residual Learning for Nonlinear Regression, *Entropy* 2020, 22, 193, doi:10.3390/e22020193.
- 28) Chen T., Guestrin C. (2016), XGBOOST: A scalable tree boosting system, *Proceedings of the 22nd ACM SIGKDD international conference on knowledge*, DOI: <https://doi.org/10.48550/arXiv.1603.02754>.
- 29) Chicco D., Warrens M.J., Jurman G. (2021), The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation, *PeerJ Computer Science*, 7, DOI: 10.7717/peerj-cs.623.
- 30) Chicu N., Prioteasa A.L., Deaconu A. (2020), Current trends and perspectives in tyre industry, *Studia Universitatis "Vasile Goldis" Arad. Economics Series Vol 30 Special Issue 2/2020*, 36-56, <https://doi.org/10.2478/sues-2020-0011>.
- 31) Chołodowski, J., and Dudziński, P. (2015), Innowacyjna metoda identyfikacji eksperymentalnej deformacji opon pojazdów Część 2: Nowatorski przetwornik

do pomiaru 3 składowych deformacji opon pojazdów, The Archives of Automotive Engineering – Archiwum Motoryzacji, 69(3), pp.3-18.

- 32) Choudhury T. A., Kahandawa G., Ibrahim M. Y., Dzitac P., Mazid A. M. and Man Z. (2017), Novel tire inflating system using extreme learning machine algorithm for efficient tire identification, 2017 IEEE International Conference on Mechatronics (ICM), Churchill, VIC, Australia, pp. 404-409, doi: 10.1109/ICMECH.2017.7921140.
- 33) Cieślík T., Metelska K. (2017), Skuteczność prognozowania zużycia gazu z wykorzystaniem metod regresji i sztucznych sieci neuronowych, Czasopismo Inżynierii Lądowej, Środowiska i Architektury, 34(64), 133–141, <https://doi.org/10.7862/rb.2017.13>.
- 34) Costa T., Silva F.J.G., Pinto Ferreira L. (2017), Improve the extrusion process in tire production using Six Sigma methodology, Procedia Manufacturing, Vol.13, p. 1104-1111, <https://doi.org/10.1016/j.promfg.2017.09.171>.
- 35) Cutler A., Cutler D., Stevens J. (2011), Random Forests, DOI:10.1007/978-1-4419-9326-7_5.
- 36) Decision Tree Regression, https://scikit-learn.org/stable/auto_examples/tree/plot_tree_regression.html#sphx-glr-auto-examples-tree-plot-tree-regression-py (dostęp: 15.06.2025).
- 37) Dharwadkar N. V., Pakhare A. R., Veeramani V., Yang W.-R. i Math R. K. M. (2022), Textile Production Line Monitoring System Using Wavelet-Regression Neural Network, Journal of Cases on Information Technology, 24(3), 1–26, <https://doi.org/10.4018/JCIT.20220701.oa11>.
- 38) Dobaj K. (2022), The use of artificial intelligence methods in the analysis of the results of vehicle braking deceleration tests in the diagnostics of the braking system of a motor vehicle, Journal of civil engineering and transport, 4(1), 33-45, DOI: 10.24136/tren.2022.003.
- 39) Dopasowanie krzywej w Pythonie, <https://softinery.com/pl/blog/dopasowanie-krzywej-w-pythonie/> (dostęp 01.06.2025).
- 40) Du M., Sun P., Zhou S., Huang H., Zhu J. (2020), A Study on the Influence of Tire Speed and Pressure on Measurement Parameters Obtained from High-Speed Tire Uniformity Testing, Vehicles, 2(3):559-573, doi.org/10.3390/vehicles2030031.

- 41) Ducic N., Jovicic, A., Manasijevic S., Radiša R, Cojbasic Z., Savković B., (2020), Application of Machine Learning in the Control of Metal Melting Production Process, Applied Sciences, DOI:10. 6048. 10.3390/app10176048.
- 42) Duvar R. et. all (2012), Real time control of tyre profiles using computer vision approach, 2012 20th Signal Processing and Communications Applications Conference (SIU), Mugla, Turkey, 2012, pp. 1-4, doi:10.1109/SIU.2012.6204670.
- 43) Eder P., Gerstorfer T., Lex C. and Amhofer T. (2020), Investigation of the Effect of Tire Deformation on Open-Wheel Aerodynamics, SAE Int. J. Advances & Curr. Prac. in Mobility 2(4):1913-1924, doi:10.4271/2020-01-0546.
- 44) ETRTO (2025) ETRTO Standards Manual, 2025 Edition. Brussels: European Tyre and Rim Technical Organisation.
- 45) European Commission (2019), A definition of AI: main capabilities and disciplines, Definition developed for the purpose of the AI HLEG's deliverables, <https://digital-strategy.ec.europa.eu/en/library/definition-artificial-intelligence-main-capabilities-and-scientific-disciplines>.
- 46) Farroni F. (2016), T.R.I.C.K.-Tire/Road Interaction Characterization & Knowledge - A tool for the evaluation of tire and vehicle performances in outdoor test sessions, Mech. Syst. Signal Process, 72–73, 808–831, DOI: <http://dx.doi.org/10.1016/j.ymssp.2015.11.019>.
- 47) Farroni F., Lamberti R., Mancinelli N., Timpone F. (2018), TRIP-ID: A tool for a smart and in-teractive identification of Magic Formula tyre model parameters from experimental data ac-quired on track or test rig, Mech. Syst. Signal Process, 102, 1–22, DOI: <http://dx.doi.org/10.1016/j.ymssp.2017.07.025>.
- 48) Fertsch M. (2020), Artificial neural pseudo-network for production control purposes, LogForum 16 (1), 7-13, DOI: <http://doi.org/10.17270/J.LOG.2020.382>.
- 49) Filipow N., Main E., Tanriver G., Raywood E., Davies G., Douglas H., Lavery A., Stanojevic S. (2023), Exploring flexible polynomial regression as a method to align routine clinical outcomes with daily data capture through remote technologies, BMC Medical Research Methodology, 23, DOI:10.1186/s12874-023-01942-4.
- 50) Funahashi T., Taki K., Koshimizu H. and Kaneko A. (2015), Fast and robust visual inspection system for tire surface thin defect, 2015 21st Korea-Japan Joint Workshop

on Frontiers of Computer Vision (FCV), Mokpo, Korea (South), pp. 1-6, doi: 10.1109/FCV.2015.7103749.

- 51) Gao M., Wu Q., Li J. et al. (2023), Temperature prediction of solar greenhouse based on NARX regression neural network, Sci Rep 13, 1563 (2023), <https://doi.org/10.1038/s41598-022-24072-1>.
- 52) Gao Y., Yang D. and Ning W. (2010), RFID application in tire manufacturing logistics, 2010 IEEE International Conference on Advanced Management Science (ICAMS 2010), Chengdu, pp. 109-112, doi: 10.1109/ICAMS.2010.5553275.
- 53) Gautam P., Azizi Y. and Chandy A. (2017), Developing a Statistical Model to Predict Tire Noise at Different Speeds, SAE Int. J. Veh. Dyn., Stab. and NVH 1(2):2017, doi:10.4271/2017-01-1507.
- 54) Gent A.N., Walter J.D. (2006), Pneumatic Tire, Mechanical Engineering Faculty Research.
- 55) Gokte S.A., Most Popular Distance Metrics Used in KNN and When to Use Them, <https://www.kdnuggets.com/2020/11/most-popular-distance-metrics-knn.html> (dostęp: 11.05.2025).
- 56) Grus, J. (2018), Data science od podstaw. Analiza danych w Pythonie, ISBN: 978-83-832-2132-8.
- 57) Guide to Unsupervised Machine Learning: 7 Real Life Examples, <https://theappsolutions.com/blog/machine-learning/unsupervised-machine-learning/> (dostęp 20.05.2025).
- 58) Guo Z. H., Qi H., Wang K. and Song H. (2009), A New Type of Tire Building Drum Based on Parallel Mechanism Position Analysis and Kinematics Simulation, 2009 International Conference on Intelligent Human-Machine Systems and Cybernetics, Hangzhou, China, pp. 129-132, doi: 10.1109/IHMSC.2009.40.
- 59) Hadi H.A et all (2017), The Implementation of Quality Function Deployment (QFD) in Tire Industry, ComTech Computer Mathematics and Engineering Applications, 8(4):223-228.
- 60) Halev-Shwartz S., Ben-David, S. (2014), Understanding Machine Learning: From Theory to Algorithms, Cambridge University Press, DOI:<https://doi.org/10.1017/CBO9781107298019>.

- 61) Han J., Kamber M. and Pei, J. (2012), *Data Mining: Concepts and Techniques*. 3rd edn. 225 Wyman Street, Waltham, MA 02451, USA.
- 62) Hastie T., Tibshirani R., Friedman J. H. (2009), *The elements of statistical learning: data mining, inference, and prediction*. 2nd ed., New York, Springer.
- 63) Hejmanowski R., Witkowski W.T. (2015), Suitability assessment of artificial neural network to approximate surface subsidence due to rock mass drainage, *Journal of Sustainable Mining*, Vol. 14, Issue 2, Article 5, DOI:10.1016/j.jsm.2015.08.014.
- 64) Hosseini Salari A., Mirzaeinejad H., Fooladi Mahani M. (2023), Tire normal force estimation using artificial neural networks and fuzzy classifiers: Experimental validation, *Applied Soft Computing*, 132, 109835, <https://doi.org/10.1016/j.asoc.2022.109835>.
- 65) Hsiao T. and Yang J.W. (2016), Iterative estimation of the tire-road friction coefficient and tire stiffness of each driving wheel, 2016 American Control Conference (ACC), Boston, MA, USA, pp. 7573-7578, doi:10.1109/ACC.2016.7526869.
- 66) Hu J., Rakheja S. and Zhang Y. (2017), Tire-road friction coefficient estimation based on longitudinal measurements, 2017 International Conference on Advanced Mechatronic Systems (ICAMechS), Xiamen, China, pp. 190-195, doi: 10.1109/ICAMechS.2017.8316533.
- 67) ISO (2003) ISO 13325:2003 Tyres — Coast-by method for measurement of tyre-to-road sound emission. Geneva: International Organization for Standardization.
- 68) ISO (2018) ISO 28580:2018 Tyres — Methods of measuring rolling resistance — Single point test and correlation of measurement results. Geneva: International Organization for Standardization.
- 69) ISO (2024) ISO 15222:2024 Tyres — Measurement of tyre-to-road sound emission under conditions representing normal driving on wet surfaces. Geneva: International Organization for Standardization.
- 70) Jackowski J., Żmuda M., Wieczorek M. (2023), Comparative analysis of small size non-pneumatic tires and pneumatic tires - radial stiffness and hysteresis, selected parameters of the contact patch, *Eksploracja i Niezawodność – Maintenance and Reliability*, 2023: 25(3), <http://doi.org/10.17531/ein/167362>.
- 71) Jafari R. (2022), *Hands-On Data Preprocessing in Python*.

- 72) Janikova D. and Bezak P. (2016), Prediction of production line performance using neural networks, 2016 Third International Conference on Artificial Intelligence and Pattern Recognition (AIPR), Łódź, Poland, pp. 1-5, doi: 10.1109/ICAIPR.2016.7585212.
- 73) Janiszewski D., Co to jest etykieta opony i jak ją czytać?, <https://www.24opony.pl/akt,0,194/co-to-jest-etykieta-opony-i-jak-ja-czytac-.html?srsId=AfmBOorFO0f08RvV5KyzQxO-mr7nyiqJSMSUe2dIsxLoSQrU30mNAfbm> (dostęp 14.03.2025).
- 74) Jeong K. M., Kim K. W., Beom H. G. and Park J. U. (2007), Finite Element Analysis of Nonuniformity of Tires with Imperfections, Tire Science and Technology, TSTCA, Vol. 35, No. 3, July – September 2007, pp. 226-238, DOI: 10.2346/1.2768607.
- 75) Johansson R. (2021), Numerical Python: Scientific Computing and Data Science Applications with Numpy, SciPy and Matplotlib, ISBN: 978-83-283-7150-7.
- 76) Kadnár M., Káčer P., Harničárová M., Valíček J., Tóth F., Bujna M., Kušnerová M., Mikuš R., Boržan M. (2023), Comparison of Linear Regression and Artificial Neural Network Models for the Dimensional Control of the Welded Stamped Steel Arms, Machines, 11(3):376, doi.org/10.3390/machines11030376.
- 77) Kamionka P., Przełomowa decyzja europarlamentu. Od 2035 r. nowe auta tylko zeroemisyjne, <https://businessinsider.com.pl/wiadomosci/przelomowa-decyzja-europarlamentu-od-2035-r-nowe-auta-tylko-elektryczne/2gln491> (dostęp 02.12.2023).
- 78) Kan Y., Hoffman S. and Carter T. (2020), Tire Rolling Radius Evolution with Tread Depth and the Implications for Tire Replacement on All-Wheel Drive Vehicles, SAE Technical Paper 2020-01-5070, doi:10.4271/2020-01-5070.
- 79) Ke G., Meng Q., Finley T., Wang T., Chen W., Ma W., Ye Q. and Liu T.-Y. (2017), LightGBM: A Highly Efficient Gradient Boosting Decision Tree, Proceedings of the 31st International Conference on Neural Information Processing Systems, 3149-3157.
- 80) Kim D.H. (2023), Developing Equipment Condition Prediction and Monitoring System Using Deep Learning Models in Automotive Production Factory, SAE Technical Paper 2023-01-0093, doi:10.4271/2023-01-0093.
- 81) Kim J.K. et al. (2019), Rubber Recycling Challenges and Developments, ISBN: 978-1-78801-348-2.

- 82) Kittichotsatsawat Y., Tippayawong N. & Tippayawong K. (2022), Prediction of arabica coffee production using artificial neural network and multiple linear regression techniques, *Scientific Reports*, 12(1), pp. 1–10, <https://doi.org/10.1038/s41598-022-18635-5>.
- 83) Koketsu Y., Takehara S., Terumichi Y., Shida Z., Ikeda T. (2017), Wear Behavior Analysis Using the Multi-mass Tire Model, *Mechanical Engineering Journal*, Vol.4, No.4, DOI: 10.1299/mej.17-00025.
- 84) Kosmela P., Olszewski A., Zedler Ł., Burger P., Formela K., Hejna A. (2021), Structural Changes and Their Implications in Foamed Flexible Polyurethane Composites Filled with Rapeseed Oil-Treated Ground Tire Rubber, *J. Compos. Sci.*, 5, 90, doi.org/10.3390/jcs5030090.
- 85) Krishnan S. et al. (2018), Bottleneck identification in a tyre manufacturing plant using simulation analysis and productivity improvement, *Materials Today: Proceedings* 5 (2018), p.24720–24730, <https://doi.org/10.1016/j.matpr.2018.10.270>.
- 86) Krynke M. (2021), Predictive Management in the Context of Industry 4.0, *Conference Quality Production Improvement – CQPI*, 3(1), 41–52, <https://doi.org/10.2478/cqpi-2021-0005>.
- 87) Kuric I. et al. (2021), Analysis of the Possibilities of Tire-Defect Inspection Based on Unsupervised Learning and Deep Learning, *Sensors* 2021, 21, 7073, <https://doi.org/10.3390/s21217073>.
- 88) Kuric I. et al. (2022), Approach to Automated Visual Inspection of Objects Based on Artificial Intelligence, *Appl. Sci.* 2022, 12, 864. <https://doi.org/10.3390/app12020864>.
- 89) Leister G. (2015), Passenger Car Tires and Wheels Development - Manufacturing - Application, ISBN 978-3-319-50118-5, <https://doi.org/10.1007/978-3-319-50118-5>.
- 90) Li C. (2021), Research on Tire Dynamic Balancing Machine Based on Least Square Method, 2021 IEEE 6th International Conference on Intelligent Computing and Signal Processing (ICSP), Xi'an, China, pp. 1372-1375, doi: 10.1109/ICSP51882.2021.9408678.
- 91) Longwic R., Lotko W. & Górski K. (2012), Modele regresyjne sieci neuronowych w zastosowaniu do identyfikacji przebiegu parametrów procesu spalania w silniku o zapłonie samoczynnym, *Czasopismo Techniczne, Mechanika*, 109(9), pp.131–140.

- 92) Lorenzi G., Reinforcement learning and the power of rewards, <https://medium.com/@lorenziga/reinforcement-learning-and-the-power-of-rewards-71baa3d51c14> (dostęp 15.04.2025).
- 93) Lu X., Shi Q., Li Y., Xu K. i Tan G. (2022), Road Adhesion Coefficient Identification Method Based on Vehicle Dynamics Model and Multi-Algorithm Fusion, *SAE International Journal of Advances & Current Practices in Mobility*, 5(2), 731–747, <https://doi.org/10.4271/2022-01-0908>.
- 94) Lukoševičius V., Makaras R., Dargužis A. (2021), Assessment of Tire Features for Modeling Vehicle Stability in Case of Vertical Road Excitation, *Applied Sciences*, 11(14):6608, DOI: <https://doi.org/10.3390/app11146608>.
- 95) Lung C. W., Chiu Y. C. and Hsieh C. W. (2016), A Laser-Based Vision System for Tire Tread Depth Inspection, 2016 International Symposium on Computer, Consumer and Control (IS3C), Xi'an, China, pp. 850-853, doi: 10.1109/IS3C.2016.216.
- 96) Luty W. (2009), An analysis of tire relaxation process during dynamic changes of cornering angle, *Journal of KONES Powertrain and Transport*, Vol. 16, No. 1.
- 97) Luty W. (2018), Simulation-based analysis of the impact of vehicle mass on stopping distance, *Eksplotacja i Niezawodność – Maintenance and Reliability*, 20(2), 182–189, <https://doi.org/10.17531/ein.2018.2.03>.
- 98) Magnuski M., Sekretne życie sieci neuronowych. Sztuczna inteligencja a neuronauka, <https://zpe.gov.pl/pdf/P2hQcr6mU> (dostęp 25.04.2024).
- 99) Mamczur M., Czym jest i jak się uczy sztuczna sieć neuronowa?, <https://mirosławmamczur.pl/czym-jest-i-jak-sie-uczy-sztuczna-siec-neuronowa/> (dostęp: 29.05.2025).
- 100) Mamczur M., Czym są hiperparametry i jak je dobrać?, <https://mirosławmamczur.pl/czym-sa-hiperparametry-i-jak-je-dobrac/> (dostęp 15.06.2022).
- 101) Mamczur M., Przykładowa sieć neuronowa MLP w Tensorflow, <https://mirosławmamczur.pl/przykladowa-siec-neuronowa-mlp-w-tensorflow/> (dostęp 29.05.2024)

- 102) Mastrodicasa D., Minervini D., Di Lorenzo E., Manzato S. et al. (2021), Tire Experimental Characterization Using Contactless Measurement Methods, SAE Technical Paper, 2021-01-1114, doi:10.4271/2021-01-1114.
- 103) Matsubara M., Ishii K., Shishido H., Kawamura S. et al. (2022), System for Strain-Distribution Visualization and Deformation Measurement of Tread Block under Fast-Rotating Tires, SAE Int. J. Veh. Dyn., Stab. and NVH 6 (1):87-97, doi: 10.4271/10-06-01-0006.
- 104) Metoda wektorów nośnych, https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstsvm.html (dostęp: 14.04.2025).
- 105) Microsoft Corporation, LightGBM, <https://lightgbm.readthedocs.io/en/v3.3.2/> (dostęp: 14.05.2023).
- 106) Miśtak S., Ministerstwo Cyfryzacji, Podział modeli uczenia maszynowego wraz z przykładami zastosowania, <https://www.gov.pl/web/popcwsparcie/podzial-modeli-uczenia-maszynowego-wraz-z-przykladami-zastosowania> (dostęp: 18.06.2025).
- 107) Mohammadi J., Ataei M., Kakaei R.K., Mikaeil R., Haghshenas S.S. (2018), Prediction of the Production Rate of Chain Saw Machine using the Multilayer Perceptron (MLP) Neural Network, Civil Engineering Journal, vol. 4., no.7, 1575-1583, doi: 10.28991/cej-0309196.
- 108) Nakajima Y. (2019), Advanced Tire Mechanics, DOI: 10.1007/978-981-13-5799-2.
- 109) Nedley Q.L., Gearig D.M. (1970), Radial improvements in tire and wheel manufacture – their effects upon radial force variation of the assembly, Society of Automotive Engineers, SAE Technical Paper 700089, Detroit, MI, <https://doi.org/10.4271/700089>.
- 110) Oertel C., Wei Y. (2012), Tyre rolling kinematics and prediction of tyre forces and moments: part I – theory and method, Vehicle System Dynamics, 50:11, 1673-1687, DOI: 10.1080/00423114.2012.694452.
- 111) Olazagoitia J.L., Perez J.A., Badea F. (2020), Identification of Tire Model Parameters with Artificial Neural Networks, Applied Sciences, 10(24):9110, <http://dx.doi.org/10.3390/app10249110>.

- 112) Owczarek P., Brzeziński M., Zelkowski J. (2022), Evaluation of light commercial vehicles operation process in a transport company using the regression modelling method, *Eksploracja i Niezawodność*, 24(3), 522-531.
- 113) Pacejka H.B. (2012), *Tire and Vehicle Dynamics* (Third edition), ISBN: 978-0-08-097016-5.
- 114) Polski Komitet Normalizacyjny, PN-ISO 13326:2002, Test methods for measuring tyre uniformity - Metody pomiaru jednorodności opony.
- 115) Popescu M.C., Balas V., Perescu P.L., Mastorakis N. (2009), Multilayer perceptron and neural networks, *WSEAS Transactions on Circuits and Systems*. 8.
- 116) Puchalski J., Warsza Z.L. (2022), Regresja i niepewność linii prostej dla pomiarów obu zmiennych x i y ze wszystkimi korelacjami, *Pomiary Automatyka Robotyka*, 24(2), 47–59, https://doi.org/10.14313/PAR_244/47.
- 117) Ramchoun H., Janati Idrissi M.A., Ghanou Y., Ettaouil M. (2016), Multilayer Perceptron: Architecture Optimization and Training, *International Journal of Interactive Multimedia and Artificial Intelligence*, 4(1): 26-30.
- 118) Rodgers B., Waddell W. (2005), *Science and technology of rubber* (third edition), Academic Press, Chapter 14 – Tire Engineering, 619–661.
- 119) Rogalski M., Co to jest uczenie maszynowe – inteligentna analiza danych?, <https://www.gov.pl/web/popcwsparcie/co-to-jest-uczenie-maszynowe--inteligentna-analiza-danych> (dostęp 16.08.2025).
- 120) Rosienkiewicz M. (2021), Artificial intelligence-based hybrid forecasting models for manufacturing systems, *Eksploracja i Niezawodność – Maintenance and Reliability*, 23 (2): 263–277, doi.org/10.17531/ein.2021.2.6.
- 121) Rucińska K., Dąbrowski K., Dębek C. (2022), Innowacje w przemyśle oponiarskim, *Polimery dla Biznesu*, tom 4, s.5-16.
- 122) Sawka, K. (2020), *Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow*, Wyd. II, aktualizacja do modułu TensorFlow 2.
- 123) Schwall M., Garg A., Shiverick J. and Conley M. (2016), Trends in Tire Pressure: An Analysis of Time-Series TPMS Data, *SAE Int. J. Passeng. Cars - Mech. Syst.*, 9(2):2016, doi:10.4271/2016-01-1574.

- 124) Seal H.L. (1967) Studies in the History of Probability and Statistics XV The historical development of Gauss linear model, *Biometrika*, <https://doi.org/10.2307/2333849>.
- 125) Sinha A., Hierarchical Reinforcement Learning with Options-Critic framework using tabular Q-Learning, <https://towardsdatascience.com/hierarchical-reinforcement-learning-56add31a21ab/> (dostęp 22.04.2025).
- 126) Skarbek-Żabkin A., Kamińska E. (2015), Kierunki zagospodarowania zużytych opon samochodowych, *Transport Samochodowy*, 1-2015.
- 127) Skoneczny S., Python – regresja liniowa, <https://softinery.com/pl/blog/python-regresja-liniowa/> (dostęp: 10.06.2025).
- 128) Skrzyniarz M. (2020), Cykl życia odpadów gumowych na przykładzie zużytych opon samochodowych, *Gospodarka Materiałowa i Logistyka*, nr 9/2020, s. 44-53, DOI:<http://dx.doi.org/10.33226/1231-2037.2020.9.5>.
- 129) Srivastava T., Guide to K-Nearest Neighbors Algorithm in Machine Learning, <https://www.analyticsvidhya.com/blog/2018/03/introduction-k-neighbours-algorithm-clustering/> (dostęp 22.05.2025).
- 130) Stinga F., Severin I., Mitache I.A. and Lascu E. (2020), Redesign of the Curing Area of the Tire Manufacturing Process, *Sustainability* 2020, 12, 6909, doi:10.3390/su12176909.
- 131) Strano S., Terzo M., Tordella C. (2021), A supervised machine learning framework for smart tires, *IEEE 6th International Forum on Research and Technology for Society and Industry (RTSI)*, Naples, Italy, pp. 364-369, doi: 10.1109/RTSI50628.2021.9597342.
- 132) Su C., Chen H. i Wen Z. (2021), Prediction of remaining useful life for lithium-ion battery with multiple health indicators, *Eksploracja i Niezawodność – Maintenance and Reliability*, 23(1), 176–183, <https://doi.org/10.17531/ein.2021.1.18>.
- 133) Sutthaweeikul R., Buhari M., Sunny A.I., Tian G.Y. (2016), Influence of lift-off on microwave open-ended waveguide time of flight based tire inspection, 2016 International Conference for Students on Applied Engineering (ICSAE), Newcastle Upon Tyne, UK, pp. 275-279, doi: 10.1109/ICSAE.2016.7810202.

- 134) Szaleniec M. (2008), Sieci neuronowe i regresja wieloraka – czyli jak okiełznać złożoność w badaniach naukowych?, Warszawa: StatSoft Polska, Instytut Katalizy i Fizykochemii Powierzchni PAN w Krakowie, dostęp [on-line] PDF.
- 135) Świdorski A, Józwiak A, Jachimowski R. (2018), Operational quality measures of vehicles applied for the transport services evaluation using artificial neural networks, *Eksploatacja i Niezawodność – Maintenance and Reliability*, 20 (2): 292–299, DOI:<http://dx.doi.org/10.17531/ein.2018.2.16>.
- 136) Tabaszewski M. (2008), Optymalizacja neuronowego modelu prognostycznego, *Diagnostyka*, 2(46), s. 109–116.
- 137) Tamborski M., Rojek I., Mikołajewski D. (2023), Revolutionizing Tire Quality Control: AI's Impact on Research, Development, and Real-Life Applications, *Applied Sciences*, 13(14):8406, doi.org/10.3390/app13148406.
- 138) Tardiff J.L., Harper M., Haakenson D., Joandrea M., Knych M. (2017), Effect of sSBR composition, functionality on tire tread compound performance characteristics, *Rubber World*, 256(6): 35-48.
- 139) Theobald O. (2017), *Machine Learning For Absolute Beginners*.
- 140) UNECE (2025) UN ECE Regulation No. 117 — Uniform provisions concerning the approval of tyres with regard to rolling sound emissions, wet grip and rolling resistance. Geneva: United Nations Economic Commission for Europe.
- 141) Viana D.P., de Sá Só Martins D.H.C., de Lima A.A., Silva F., Pinto M.F., Gutiérrez R.H.R., Monteiro U., Vaz L., Prego T., Andrade F.A.A., et al. (2023), Diesel Engine Fault Prediction Using Artificial Intelligence Regression Methods, *Machines* 2023, 11, 530, doi.org/10.3390/machines11050530.
- 142) Vo D., Marzbani H., Fard M. and Jazar R., (2017), A Novel Kinematic Model of a Steerable Tire for Examining Kingpin Moment during Low-Speed-Large-Steering Angle Cornering, *SAE Int. J. Passeng. Cars - Mech. Syst.*, 10(1):2017, [doi:10.4271/2016-01-8030](https://doi.org/10.4271/2016-01-8030).
- 143) Wang Y., Sua B., Wua J. (2012), Simulation and optimization of giant radial tire vulcanization process, *International Conference on Advances in Computational Modeling and Simulation*, *Procedia Engineering*, vol. 31, 2012, p. 723 – 726, <https://doi.org/10.1016/j.proeng.2012.01.1092>.

- 144) WdK (2025) WdK Guidelines for Tyre Approval Tests. Frankfurt am Main: Wirtschaftsverband der deutschen Kautschukindustrie e.V.
- 145) Wei Y., Oertel C. and Shen X. (2012), Tyre rolling kinematics and prediction of tyre forces and moments: part II – simulation and experiment, *Vehicle System Dynamics*, 50:11, 1689-1706, DOI: 10.1080/00423114.2012.694453.
- 146) Weyssenhoff A., Opala M., Koziak S., Melnik R. (2019), Characteristics and investigation of selected manufacturing defects of passenger car tires, *Transportation Research Procedia*, Volume 40, 119-126, <https://doi.org/10.1016/j.trpro.2019.07.020>.
- 147) What Is Overfitting?, <https://www.mathworks.com/discovery/overfitting.html> (dostęp 31.03.2025).
- 148) Wiegand, B. (2016), Estimation of the Rolling Resistance of Tires, SAE Technical Paper 2016-01-0445, doi:10.4271/2016-01-0445.
- 149) Xingyu W., Ligu Z., Yaowei L., Zhi W. and Tian L. (2021), Study on tire blowout characteristics of insert supporting run-flat tire, 2021 5th CAA International Conference on Vehicular Control and Intelligence (CVCI), Tianjin, China, 2021, pp. 1-6, doi:10.1109/CVCI54083.2021.9661237.
- 150) Xu N., Askari H., Huang Y., Zhou J. and Khajepour A. (2022), Tire Force Estimation in Intelligent Tires Using Machine Learning, *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 4, pp. 3565-3574, doi: 10.1109/TITS.2020.3038155.
- 151) Xu N., Guo K. and Zhang, X. (2013), UniTire Model for Tire Forces and Moments under Combined Slip Conditions with Anisotropic Tire Slip Stiffness, *SAE Int. J. Commer. Veh.* 6(2):2013, doi:10.4271/2013-01-2362.
- 152) Xu N., Huang Y., Askari H. and Tang Z. (2021), Tire Slip Angle Estimation Based on the Intelligent Tire Technology, *IEEE TRANSACTIONS ON VEHICULAR TECHNOLOGY*, VOL. 70, NO. 3.
- 153) Yoon Y., Lee J., Yum K., Lee S.K. et al. (2022), Development of a Prediction Model for Tire Tread Pattern Noise Based on Convolutional Neural Network with RMSProp Algorithm, SAE Technical Paper 2022-01-0884, doi:10.4271/2022-01-0884.
- 154) Yu Y., Ren J., Cui W., Yan H. and Yang W. (2021), Design and Static Analysis of Rotary Manipulator for Fixed-point Tire Vulcanization, 2021 IEEE 7th International

Conference on Control Science and Systems Engineering (ICCSSE), Qingdao, China, 2021, pp. 73-77, doi:10.1109/ICCSSE52761.2021.9545100.

- 155) Zajac T., Czym są sztuczne sieci neuronowe?, <https://bluemetrika.com/co-to-sa-sztuczne-sieci-neuronowe/> (dostęp: 15.05.2025).
- 156) Zhang J., Tan J., Liu X., et al. (2016), Energy saving curing and precision manufacturing technology of tires, AIP Conference Proceedings 1713, 130002 (2016), <https://doi.org/10.1063/1.4942334>.
- 157) Zhang Z., Fu H., Liang X., Chen X., Tan D. (2020), Comparative Analysis of Static and Dynamic Performance of Nonpneumatic Tire with Flexible Spoke Structure, *Strojniški vestnik - Journal of Mechanical Engineering* 66(2020)7-8, 458-466, DOI:10.5545/sv.jme.2020.6676.
- 158) Zhu B., Hu D., Liao F., Chen J., Su B., Wu J., Wang Y. (2023), A Fast Approach to Optimize Tread Pattern Shape for Tire Noise Reduction, *Appl. Sci.*, 13, 10256, <https://doi.org/10.3390/app131810256>.
- 159) Zhu J., Han K., Wang S. (2021), Automobile tire life prediction based on image processing and machine learning technology, *Adv. Mech. Eng.* 2021, 13, 3, DOI: <http://dx.doi.org/10.1177/16878140211002727>.
- 160) Zhu Q. and Ai X. (2018), The Defect Detection Algorithm for Tire X-Ray Images Based on Deep Learning, 2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC), Chongqing, China, pp. 138-142, doi: 10.1109/ICIVC.2018.8492908.