



Imię i nazwisko autora rozprawy: Oskar Wysocki
Dyscyplina naukowa: Budowa i eksploatacja maszyn

ROZPRAWA DOKTORSKA

Tytuł rozprawy w języku polskim:

Odwzorowanie właściwości energetycznych silników spalinowych pojazdów użytkowych z wykorzystaniem pomiarów trakcyjnych

Tytuł rozprawy w języku angielskim:

Mapping the energetic characteristics of internal combustion engines of commercial vehicles using operational data

Promotor	Drugi promotor
<i>podpis</i>	<i>podpis</i>
dr hab. inż. Jacek Kropiwnicki	-
Promotor pomocniczy	Kopromotor
<i>podpis</i>	<i>podpis</i>
dr inż. Jacek Czyżewicz	-



OŚWIADCZENIE

Autor rozprawy doktorskiej: Oskar Wysocki

Ja, niżej podpisany(a), wyrażam zgodę/nie wyrażam zgody* na bezpłatne korzystanie z mojej rozprawy doktorskiej zatytułowanej:

Odwzorowanie właściwości energetycznych silników spalinowych pojazdów użytkowych z wykorzystaniem pomiarów trakcyjnych
do celów naukowych lub dydaktycznych.¹

Gdańsk, dnia

.....
podpis doktoranta

Świadomy(a) odpowiedzialności karnej z tytułu naruszenia przepisów ustawy z dnia 4 lutego 1994 r. o prawie autorskim i prawach pokrewnych (Dz. U. z 2006 r., nr 90, poz. 631) i konsekwencji dyscyplinarnych określonych w ustawie Prawo o szkolnictwie wyższym (Dz. U. z 2012 r., poz. 572 z późn. zm.),² a także odpowiedzialności cywilno-prawnej oświadczam, że przedkładana rozprawa doktorska została napisana przeze mnie samodzielnie.

Oświadczam, że treść rozprawy opracowana została na podstawie wyników badań prowadzonych pod kierunkiem i w ścisłej współpracy z promotorem Jackiem Kropiwnickim oraz promotorem pomocniczym Jackiem Czyżewiczem.

Niniejsza rozprawa doktorska nie była wcześniej podstawą żadnej innej urzędowej procedury związanej z nadaniem stopnia doktora.

Wszystkie informacje umieszczone w ww. rozprawie uzyskane ze źródeł pisanych i elektronicznych, zostały udokumentowane w wykazie literatury odpowiednimi odnośnikami zgodnie z art. 34 ustawy o prawie autorskim i prawach pokrewnych.

Potwierdzam zgodność niniejszej wersji pracy doktorskiej z załączoną wersją elektroniczną.

Gdańsk, dnia

.....
podpis doktoranta

Ja, niżej podpisany(a), wyrażam zgodę/nie wyrażam zgody* na umieszczenie ww. rozprawy doktorskiej w wersji elektronicznej w otwartym, cyfrowym repozytorium instytucjonalnym Politechniki Gdańskiej, Pomorskiej Bibliotece Cyfrowej oraz poddawania jej procesom weryfikacji i ochrony przed przywłaszczeniem jej autorstwa.

Gdańsk, dnia

.....
podpis doktoranta

*) niepotrzebne skreślić

¹ Zarządzenie Rektora Politechniki Gdańskiej nr 34/2009 z 9 listopada 2009 r., załącznik nr 8 do instrukcji archiwalnej PG.

² Ustawa z dnia 27 lipca 2005 r. Prawo o szkolnictwie wyższym: Rozdział 7 Odpowiedzialność dyscyplinarna doktorantów, Art. 226.





OPIS ROZPRAWY DOKTORSKIEJ

Autor rozprawy doktorskiej: Oskar Wysocki

Tytuł rozprawy doktorskiej w języku polskim:

Odwzorowanie właściwości energetycznych silników spalinowych pojazdów użytkowych z wykorzystaniem pomiarów trakcyjnych

Tytuł rozprawy w języku angielskim:

Mapping the energetic characteristics of internal combustion engines of commercial vehicles using operational data

Język rozprawy doktorskiej: Polski

Promotor rozprawy doktorskiej: Jacek Kropiwnicki

~~Drugi promotor rozprawy doktorskiej*:~~

Promotor pomocniczy rozprawy doktorskiej*: Jacek Czyżewicz

~~Kopromotor rozprawy doktorskiej*:~~ <imię, nazwisko>

Data obrony:

Słowa kluczowe rozprawy doktorskiej w języku polski: charakterystyka silnika, silnik spalinowy, pojazdy użytkowe, właściwości energetyczne, uczenie maszynowe, układ napędowy

Słowa kluczowe rozprawy doktorskiej w języku angielskim: engine characteristics, combustion engine, commercial vehicle, energetic characteristics, drivetrain, machine learning

Streszczenie rozprawy w języku polskim:

Przedmiotem rozprawy jest odwzorowanie właściwości energetycznych silnika spalinowego z wykorzystaniem danych pomiarowych, uzyskanych podczas bieżącej eksploatacji pojazdu użytkowego. W pierwszej części pracy omówione zostały podstawy działania pojazdów użytkowych oraz występowanie stanów statycznych i dynamicznych podczas rzeczywistej eksploatacji silnika. Następnie omówiono metody odwzorowania charakterystyk silnika spalinowego. Jako alternatywne do dotychczasowo stosowanego dopasowywania funkcją



wielomianową, zaproponowano podejście na bazie Uczenia Maszynowego (K-Najbliższych Sąsiadów oraz Sztuczne Sieci Neuronowe). W części badawczej, przeanalizowano dobór metod odwzorowania przy wykorzystaniu wyników badań stanowiskowych, traktowanych jako referencyjne. Stanowisko pomiarowe zostało specjalnie w tym celu zaprojektowane przez autora oraz wykonane w firmie Zoeller Tech. Następnie aplikując wcześniej przeanalizowane metody, odwzorowano charakterystykę silnika pojazdu użytkowego przy użyciu danych trakcyjnych pochodzących z jednego dnia pracy pojazdu. W ostatnim rozdziale zaprezentowano wykorzystanie odwzorowanej charakterystyki w celu oceny sprawności eksploatacyjnej układu napędowego śmieciarki.

Streszczenie rozprawy w języku angielskim:

The thesis investigates mapping of energetic characteristics of internal combustion engines using data, measured during regular operation of commercial vehicles. In the first part, the basics of commercial vehicle operation and the occurrence of static and dynamic states during daily operation of the engine were discussed. Then, methods for mapping energetic characteristics were presented. As an alternative to widely used polynomial regression, a machine learning approach was proposed, using K-Nearest Neighbors and Artificial Neural Networks algorithms. In the experimental part of this study, the methods were analyzed by using data from measurements on a test bench, and the results were considered as a reference. The test bench was designed by the author and manufactured by refuse collection vehicles' producer Zoeller Tech. Then, the previously optimized methods were used for mapping the energetic characteristics by using the data collected during one operational day of a commercial vehicle. In the last chapter, the application of mapped engine characteristic was presented, showing the possibility of calculating the efficiency of the commercial vehicle's drivetrain.



Spis treści

1. DEFINICJA POJĘĆ.....	10
1.1. Warunki pracy silnika.....	10
1.2. Stan pracy silnika.....	10
1.3. Proces stanu i proces warunków pracy.....	10
1.4. Masowy strumień paliwa	11
1.5. Prędkość kątowna i obrotowa	11
1.6. Moment obrotowy.....	11
1.7. Pole pracy i punkt pracy	11
1.8. Charakterystyka ogólna silnika ZS	13
1.9. Stany statyczne a stany dynamiczne.....	14
2. PODSTAWY DZIAŁANIA POJAZDÓW UŻYTKOWYCH	15
2.1. Przegląd pojazdów użytkowych z zabudową.....	15
2.2. Realizacja funkcji zabudowy i obciążenie układu	17
2.3. Odbiór mocy z silnika spalinowego na potrzeby zabudowy.....	18
2.3.1. Przystawki odbioru mocy zależne od sprzęgła.....	19
2.3.2. Przystawki odbioru mocy niezależne od sprzęgła	19
2.3.3. Zakres odbieranej mocy i parametry przystawki	20
2.4. Podstawy działania śmieciarek.....	21
2.5. Rodzaje połączenia przystawki z pompą stosowane w śmieciarkach.....	25
3. UKŁAD NAPĘDOWY POJAZDU UŻYTKOWEGO.....	27
3.1. Wstęp do metody Grafów Wiązań	27
3.2. Układ napędowy pojazdu użytkowego w konwencji Grafów Wiązań	29
3.2.1. Schemat blokowy	29
3.2.2. Bazowy model układu napędowego w konwencji Grafów Wiązań.....	30
3.3. Układ napędowy śmieciarki	32
3.4. Analiza sprawności układu napędowego śmieciarki.....	34
3.5. Podsumowanie	36
4. CEL I TEZA PRACY	37



Teza pracy:.....	37
Cel pracy:.....	37
5. REJESTRACJA PARAMETRÓW PRACY POJAZDU.....	38
5.1. Magistrala CAN w pojeździe ciężarowym	38
5.2. Standard FMS.....	39
5.3. Przetwarzanie danych.....	40
5.4. Wykorzystanie FMS w zagadnieniach transportowych	41
5.5. Moment obrotowy ECU, prędkość obrotowa i strumień masowy paliwa	42
6. PRZETWARZANIE SYGNAŁÓW Z INTERFEJSU FMS.....	45
6.1. Zarys problematyki przetwarzania sygnałów z pojazdu.....	45
6.2. Interpolacja sygnału G_e	46
6.3. Wygładzenie sygnałów n i M	48
7. METODY ODWZOROWANIA CHARAKTERYSTYKI SILNIKA	52
7.1. Aproksymacja funkcją wielomianową.....	52
7.1.1. Regresja liniowa – podejście ogólne	52
7.1.2. Regresja wielomianowa jako szczególny przypadek regresji liniowej	54
7.1.3. Wykorzystanie aproksymacji funkcją wielomianową – przegląd literatury.....	55
7.2. Uczenia maszynowe w kontekście badań silników spalinowych	55
7.2.1. Czym jest Uczenie Maszynowe (Machine Learning)	55
7.2.2. Podstawy analizy i problemy w Uczeniu Maszynowym	58
7.2.3. Uwagi do Uczenia Maszynowego	62
7.2.4. Ocena dokładności dopasowania modelu	63
7.2.5. Ocena modelu w prognozowania łącznego zużycia paliwa.....	64
7.2.6. Aplikacja Uczenia Maszynowego do badań silników spalinowych – przegląd literatury	65
7.3. Metoda K-Najbliższych Sąsiadów (KNN).....	68
7.4. Sztuczna sieć neuronowa.....	70
7.5. Przykłady obliczeniowe rozważanych metod odwzorowania	72



7.5.1.	Aproksymacja funkcją wielomianową – dane ze stanu statycznego.....	72
7.5.2.	Aproksymacja funkcją wielomianową – dane ze stanu dynamicznego	74
7.5.3.	KNN – poszukiwanie stanów podobnych w danych ze stanu dynamicznego	76
7.5.4.	Sztuczna sieć neuronowa –dane ze stanu dynamicznego	79
7.6.	Podsumowanie	80
8.	STANY DYNAMICZNE SILNIKA W CZASIE RZECZYWISTEJ EKSPLOATACJI	82
8.1.	Kryterium maksymalnej odchyłki (KMO).....	82
8.2.	Kryterium maksymalnej pochodnej (KMP)	83
8.3.	Zastosowanie kryteriów do danych z rzeczywistej eksploatacji pojazdu.	84
8.4.	Wyniki poszukiwania punktów pomiarowych pracy silnika w stanie statycznym.....	86
9.	ANALIZA DOBORU METODY ODWZOROWANIA CHARAKTERYSTYK PRZY WYKORZYSTANIU DANYCH STANOWISKOWYCH	91
9.1.	Przebieg badań silnika przy użyciu stanowiska pomiarowego	92
9.2.	Badania w stanie statycznym.....	93
9.2.1.	Procedura szybkiego wyznaczenia charakterystyki statycznej.....	93
9.2.2.	Weryfikacja procedury w trzech testach stanowiskowych	95
9.2.3.	Ocena powtarzalności	96
9.3.	Badania w stanie dynamicznym	97
9.3.1.	Opis badania w stanie dynamicznym.....	97
9.3.2.	Wzajemne opóźnienie pomiędzy parametrami w stanie dynamicznym	100
9.4.	Procedura obliczeniowa weryfikacji metod na danych z testu dynamicznego	102
9.5.	Model z wykorzystaniem regresji wielomianowej dla danych z testu w stanie dynamicznym.....	102
9.5.1.	Opis zastosowanych modeli.....	102
9.5.2.	Omówienie wyników	103





9.6.	Model KNN dla danych z testu w stanie dynamicznym.....	106
9.6.1.	Dobór optymalnych parametrów wejściowych i parametru k	106
9.6.2.	Omówienie wyników.....	107
9.7.	ANN dla danych z testu w stanie dynamicznym.....	110
9.7.1.	Dobór optymalnych parametrów wejściowych i liczby neuronów w warstwie ukrytej.....	110
9.7.2.	Omówienie wyników.....	112
9.8.	Badanie weryfikacyjne – symulacja cyklu roboczego	116
9.8.1.	Opis badania weryfikacyjnego	116
9.8.2.	Obliczenia zużycia paliwa G_e	117
9.8.3.	Omówienie wyników testu weryfikacyjnego	118
9.9.	Podsumowanie.....	120
10.	APLIKACJA METOD DO DANYCH Z POMIARÓW TRAKCYJNYCH	121
10.1.	Przeprowadzone testy trakcyjne	121
10.2.	Metoda selekcji punktów pomiarowych.....	122
10.3.	Modele RW, KNN i ANN obliczone na podstawie danych z pomiarów trakcyjnych	124
10.4.	Symulacja pracy silnika	126
10.4.1.	Wyznaczenie przebiegów testowych.....	126
10.4.2.	Wyniki końcowej weryfikacji modeli	127
11.	OCENA SPRAWNOŚCI UKŁADU NAPĘDOWEGO ŚMIECIARKI.....	130
11.1.	Cykle robocze pracy zabudowy śmieciarki	130
11.2.	Zależność M od M_s i n	132
11.3.	Przebieg M w zależności od n	133
11.4.	Obliczenie łącznego zużycie paliwa w cyklach roboczych	133
11.5.	Ocena sprawność układu napędowego.....	135
11.6.	Zastosowanie metody.....	137
12.	UWAGI KOŃCOWE I WNIOSKI.....	138
	Literatura.....	140



Wykaz rysunków	147
Wykaz tabel.....	152
A. ZAŁACZNIK - STANOWISKO BADAWCZE.....	153
1.1. Przegląd stosowanych rozwiązań.....	153
1.1.1. Hamownie silnikowe	153
1.1.2. Hamownie podwoziowe.....	155
1.1.1. Hamownie WOM.....	155
1.2. Koncepcja stanowiska badawczego.....	157
1.3. Założenia projektowe.....	160
1.3.1. Wymuszanie stanów pracy.....	160
1.3.2. Maksymalna odbierana moc	160
1.3.3. Symulacja pracy zabudowy.....	161
1.3.4. Rejestracja danych.....	161
1.3.5. Demontowalna konstrukcja.....	161
1.4. Układ hydrauliczny stanowiska.....	161
1.4.1. Pompa hydrauliczna.....	162
1.4.2. Rozproszenie energii cieplnej do otoczenia przez zbiornik i chłodnice	164
1.5. Układ sterowania stanowiska	165
1.6. Model energetyczny stanowiska według metody Grafów Wiązań.....	166
1.7. Model 3D i zrealizowany projekt stanowiska.....	168

1. DEFINICJA POJĘĆ

Rozważając temat odwzorowywania charakterystyk silnika spalinowego niezbędne jest na początku niniejszej pracy zdefiniowanie pojęć, które będą w niej niejednokrotnie używane.

Podczas pracy silnika spalinowego zachodzi wiele zjawisk fizycznych. Każde takie zjawisko może być opisane przez odpowiednią wielkość fizyczną (lub kilka wielkości). Każda taka wielkość traktowana jest jako parametr pracy silnika. Tak więc praca silnika może zostać kompleksowo opisana przez ogół tych wielkości, czyli przez parametry pracy.

1.1. Warunki pracy silnika

Parametry wejściowe zawierają informacje o warunkach w jakich silnik pracuje. Parametrami wejściowymi są m.in.: moment oporu, sterowanie silnika przez operatora lub sterownik, warunki otoczenia, warunki atmosferyczne. Zatem mają one wpływ na pracę ale nie są wynikiem tej pracy. Parametry wejściowe definiują **warunki pracy silnika**.

1.2. Stan pracy silnika

Zespół zjawisk zachodzących wewnątrz silnika określa **stan pracy silnika**. Parametry opisujące stan pracy to na przykład: średnie ciśnienie indukowane w cylindrze, ciśnienie doładowania, kąt wyprzedzenia wtrysku, kąt wyprzedzenia zapłonu, dawka paliwa, temperatura powietrza napełniającego cylindry, temperatura czynnika w cylindrze. Informacje o powyższych parametrach są często niedostępne podczas testowania silnika, a budowa modeli na nich opartych jest bardzo skomplikowana. Dlatego preferowaną metodą jest traktowanie modelu silnika jako model typu „czarna skrzynka”. Na podstawie parametrów wyjściowych takich jak prędkość obrotowa i moment obrotowy możliwy jest pośredni opis stanu pracy silnika.

1.3. Proces stanu i proces warunków pracy

Zbiory kolejno występujących po sobie stanów pracy lub warunków pracy w czasie, definiowane są odpowiednio jako **proces stanu pracy** oraz **proces warunków pracy** [1].

W niniejszej pracy przyjęto, że proces warunków pracy silnika zależny będzie głównie od przebiegu momentu oporowego. Podczas jazdy pojazdu moment oporowy związany jest z momentem oporowym układu napędowego kół jezdnych, natomiast podczas postoju i pracy zabudowy pojazdu użytkowego, moment oporowy generowany jest przez przystawkę odbioru mocy. Wpływ warunków otoczenia oraz warunków

atmosferycznych został pominięty, przy założeniu ich jednakowego wpływu na wszystkie prezentowane metody odwzorowania właściwości energetycznych.

Stan pracy silnika oraz proces stanu definiowany będzie pośrednio na podstawie zarejestrowanej prędkości obrotowej, momentu obrotowego oraz masowego strumienia paliwa.

1.4. Masowy strumień paliwa

Masowy strumień paliwa G_e , może być nazywany również sekundowym zużyciem paliwa [2]:

$$G_e = \frac{m_c}{T_c} \left[\frac{g}{s} \right] \quad (1.1)$$

Gdzie m_c – dawka paliwa dostarczona w jednym cyklu pracy do silnika, T_c – czas cyklu pracy silnika.

1.5. Prędkość kątowna i obrotowa

Prędkość kątowna ω wału korbowego silnika definiowana jest jako zmiana kąta obrotu wału korbowego α w czasie t :

$$\omega = \frac{d\alpha}{dt} \left[\frac{1}{s} \right] \quad (1.2)$$

W praktyce inżynierskiej częściej stosowane jest pojęcie **prędkości obrotowej** silnika n , która jest określona wzorem:

$$n = \frac{\omega}{2\pi} * 60 \left[\frac{obr}{min} \right] \quad (1.3)$$

1.6. Moment obrotowy

Pojęcie **momentu obrotowego** M silnika używanego w tej pracy odnosi się do średniej wartości momentu obrotowego generowanego przez silnik w założonym czasie t [2]:

$$M = \frac{1}{t} \int_0^t M(t) \cdot dt \quad (1.4)$$

1.7. Pole pracy i punkt pracy

Zarówno prędkość kątowna jak i moment obrotowy mogą przyjmować wartości z pewnego zakresu charakterystycznego dla danego silnika:

$$\omega \in \langle \omega_{min}; \omega_{max} \rangle \quad (1.5)$$

$$M \in \langle M_{\min}; M_{\max} \rangle \quad (1.6)$$

Ekstremalne wartości prędkości kątowej silnika przyjmują stałe wartości, z kolei ekstremalne wartości momentu obrotowego są funkcją prędkości kątowej:

$$\omega_{\min} = \text{const} \quad \omega_{\max} = \text{const} \quad (1.7)$$

$$M_{\min} = f_{\min}(\omega) \quad M_{\max} = f_{\max}(\omega) \quad (1.8)$$

Minimalna prędkość, której odpowiada prędkość biegu jałowego utrzymywana jest przez sterownik silnika (z ang. Engine Control Unit - ECU). Zwykle jest to najniższa prędkość, przy której silnika zachowuje stabilną pracę, jednocześnie generując moment obrotowy wystarczający na pokonanie oporów wewnętrznych. W silnikach ZS stosowanych w pojazdach użytkowych, a więc w silnikach o stosunkowo dużej pojemności skokowej, minimalna prędkość wynosi zwykle około $600 \text{ obr}/\text{min}$, czyli $62,8 \text{ rad}/\text{s}$. W pojazdach osobowych wyposażonych w mniejsze silniki ZS, na biegu jałowym silnik pracuje przy $700 - 1000 \text{ obr}/\text{min}$, czyli $73 - 105 \text{ rad}/\text{s}$.

Maksymalną prędkość obrotową ogranicza konstrukcja silnika [2,3]. W pojazdach użytkowych wynosi zwykle $2500 \text{ obr}/\text{min}$, jednak pracę silnika w zakresie prędkości powyżej $2000 \text{ obr}/\text{min}$ obserwuje się niezwykle rzadko. Spowodowane jest to faktem, iż maksymalny moment obrotowy generowany jest między 1000 a $1200 \text{ obr}/\text{min}$, a wielostopniowa przekładnia umożliwia pracę w powyższym zakresie nawet podczas przejazdów z najwyższą dopuszczalną prędkością ($90 \text{ km}/\text{h}$). Praca silnika z wyższą prędkością obrotową charakteryzuje się niższą sprawnością i jest ekonomicznie nieuzasadniona. Za nieprzekroczenie maksymalnej prędkości odpowiada ponownie sterownik silnika, który przy próbie nadmiernego rozpędzenia silnika odcina dopływ paliwa do cylindra. Jest to działanie konieczne, aby zapobiec uszkodzeniu silnika.


Maksymalny moment obrotowy generowany na wale korbowym silnika jest funkcją prędkości kątowej i jest cechą charakterystyczną dla danego silnika. W ogólności dla silników ZS maksymalny moment ograniczony jest granicą dymienia [2].

Minimalny moment obrotowy jest również zależny od prędkości kątowej i przyjmuje wartości ujemne, ponieważ osiągany jest podczas pracy silnika jako hamulca (tzw. hamowanie silnikiem). W ogólności można przyjąć, że im większa prędkość kątowa, tym większy moment hamujący (ujemny moment obrotowy).

Moment obrotowy oraz prędkość kątowa jako para parametrów ($M; \omega$) nazywana jest **punktem pracy** silnika. Z kolei zakres punktów pracy możliwy do uzyskania podczas eksploatacji silnika nazywany jest **połem pracy**. Pole pracy (L_s) składa się z dwóch obszarów:

$$L_s = L_{s_1} + L_{s_2} \quad (1.9)$$

Gdzie L_{s_1} to pole pracy leżące nad osią prędkości kątowej, L_{s_2} to pole pracy leżące pod osią prędkości kątowej. Silnik pracuje w polu L_{s_2} podczas gdy wykorzystywany jest jako hamulec. Graficzna interpretacja pola pracy przedstawiona jest na Rys. 1.1.



Rys. 1.1. Pole pracy silnika: $L_s = L_{s_1} + L_{s_2}$ (kolorem szarym zaznaczono część pola pracy silnika, gdzie jest on wykorzystywany jako hamulec: L_{s_2}) [5].

1.8. Charakterystyka ogólna silnika ZS

Właściwości użytkowe silnika spalinowego mogą być przedstawione jako zależność między wielowymiarowo opisanymi warunkami pracy a wielowymiarowo opisanym stanem jego pracy. Zatem wielowymiarowa charakterystyka silnika zależna jest od zbioru parametrów, w skład którego wchodzi m.in.: prędkość kątowa, moment obrotowy, temperatura chłodziwa, temperatura oleju, masowy strumień paliwa, średnie ciśnienie indykowane w cylindrze itd.

W niniejszej pracy pominięty został wpływ zmian stanu cieplnego silnika, zakładając że silnik pracuje w stanie rozgrzanym i jego niewielkie zmiany temperatury nie mają istotnego wpływu na dokładność proponowanych metod. Zatem temperatura chłodziwa oraz temperatura oleju została usunięta ze zbioru parametrów.

Z energetycznego punktu widzenia, interesującymi wyjściowymi parametrami są te charakteryzujące strumień energii przekazywanej odbiornikowi, a więc moment obrotowy i prędkość kątowa. Z kolei strumień energii dostarczany do silnika określony

jest przez masowy strumień paliwa. Zależność między powyższymi parametrami nazywana jest statyczną **charakterystyką ogólną silnika**:

$$G_e = f(M, \omega), \text{ gdzie } M, \omega \in L_s \quad (1.10)$$

1.9. Stany statyczne a stany dynamiczne

Definiując zbiór warunków pracy jako W , zbiór parametrów stanu pracy jako S , pracę silnika charakteryzuje zbiór P , który jest sumą zbiorów W i S [1]:

$$W = \{W_1, W_2, \dots, W_i\} \quad (1.11)$$

$$S = \{S_1, S_2, \dots, S_i\} \quad (1.12)$$

$$P = W \cup S = \{P_1, P_2, \dots, P_i\} \quad (1.13)$$

Formalnie praca silnika ma charakter statyczny, gdy zarówno warunki pracy jak i stan pracy silnika są niezależne od czasu, a więc pochodne wszystkich parametrów po czasie przyjmują zerowe wartości:

$$\frac{\partial P_k(t_i)}{\partial t} = 0 \quad (1.14)$$

W teorii jeśli powyższy warunek nie jest spełniony, stan pracy silnika traktowany jest jako dynamiczny. Z. Chłopek w swojej pracy [1] uszczegółowił koncepcję podziału na stany statyczne i dynamiczne uwzględniając rzeczywiste możliwości prowadzenia badań silników spalinowych. Autor uznał, zerowa wartość pochodnej stanowi zbyt ostre kryterium i zaproponował graniczną wartość pochodnej danego parametru ε_k . Zbiór granicznych wartości ε_i definiowany jest jako:

$$\varepsilon = \{\varepsilon_1, \varepsilon_2, \dots, \varepsilon_k\} \quad (1.15)$$

Dodatkowo, analizując zarejestrowane wartości, konieczne jest zastosowanie filtrów dolnoprzepustowych aby wyeliminować wpływ procesów szybkozmiennych. Przefiltrowane sygnały oznaczone są jako \bar{P}_i :

$$\frac{\partial \bar{P}_k(t_i)}{\partial t} < \varepsilon_k \quad (1.16)$$

Wartość ε_k może być ustalona dowolnie, w zależności od deklarowanej dokładności badań. Podsumowując, każdy stan pracy w którym pochodne wszystkich przefiltrowanych wartości parametrów są mniejsze niż odpowiadające im założone graniczne wartości ε_k uznawany jest za statyczny. Każdy inny stan jest stanem dynamicznym. Zagadnienie filtrowania sygnałów poruszone jest w rozdziale 5, a szersza analiza kwalifikowalności stanów pracy jako dynamiczne w rozdziale 7.

2. PODSTAWY DZIAŁANIA POJAZDÓW UŻYTKOWYCH

Poniższy rozdział ma na celu przybliżenie zasad działania pojazdów użytkowych wyposażonych w zabudowę. Omówione zostały najczęściej realizowane przez zabudowy funkcje oraz spowodowane nimi obciążenie układu napędowego. Przedstawiono sposób odbioru mocy z silnika spalinowego przy użyciu przystawki odbioru mocy. Przystawka została szczegółowo opisana pod kątem stosowanych rozwiązań konstrukcyjnych oraz zakresu odbieranej mocy. Spośród pojazdów użytkowych wyszczególniona została śmieciarka, z uwagi na planowane wykorzystanie efektów niniejszej pracy przy optymalizacji układów napędowych tych pojazdów, zgodnie ze zleceniem producenta – firmy Ekocel. Ponadto przedstawiono opracowaną przez autora metodę obliczenia wymaganej prędkości obrotowej silnika na podstawie geometrii elementów wykonawczych i kinematyki mechanizmu prasującego.

2.1. Przegląd pojazdów użytkowych z zabudową

Niniejsza praca dotyczy silników spalinowych, w które wyposażone są pojazdy użytkowe. Obok pojazdów wykorzystujących silnik wyłącznie do realizacji funkcji związanych z transportem tj. napędu kół jezdnych (oraz urządzeń pomocniczych, np. klimatyzacji kabiny kierowcy) i pokonywania oporów ruchu pojazdu, istnieje ciekawa grupa pojazdów użytkowych, które wykorzystują ten sam silnik spalinowy również do realizacji funkcji zabudowy, a więc do napędu jej podzespołów. Takie pojazdy to m.in. wywrotki, betonomieszarki, pompy do betonu, samochody pożarnicze, hakowce, holowniki drogowe, samochody chłodnie, zamiatarki, wysięgniki samochodowe, hydrauliczne dźwigi samochodowe (tzw. HDSy) oraz pojazdy do usuwania odpadów z pojemników (śmieciarki). Moc z silnika spalinowego odbierana jest zwykle przez pompę hydrauliczną, generator elektryczny lub dodatkowy wał napędowy. Następnie funkcja zabudowy realizowana jest przez element wykonawczy np. siłownik hydrauliczny, silnik hydrauliczny, silnik elektryczny, agregat chłodniczy. Przykłady najczęściej spotykanych pojazdów użytkowych przedstawiono w Tabeli 1.

Przykłady układów napędowych oraz przykłady realizacji funkcji zabudowy prezentowane w dalszej części pracy odnoszą się głównie do pojazdów do usuwania odpadów z pojemników (PUOP), popularnie zwanych śmieciarkami.

Tabela 1. Przykłady pojazdów użytkowych z wyszczególnionym elementem odbierającym moc z silnika spalinowego oraz elementami wykonawczymi.

		
<p>Pojazd Odbiór mocy Element wykonawczy</p>	<p>Betonomieszarka Pompa hydrauliczna Silnik hydrauliczny</p>	<p>Pompa betonu Pompa hydrauliczna Pompa betonu i siłowniki hydrauliczne</p>
		
<p>Pojazd Odbiór mocy Element wykonawczy</p>	<p>Wywrotka Pompa hydrauliczna Siłownik hydrauliczny teleskopowy</p>	<p>Hydrauliczny dźwig samochodowy Pompa hydrauliczna Siłowniki hydrauliczne</p>
		
<p>Pojazd</p>	<p>Chłodnia</p>	<p>Zamiatarka</p>
<p>Odbiór mocy</p>	<p>Generator elektryczny</p>	<p>Pompa hydrauliczna</p>
<p>Element wykonawczy</p>	<p>Agregat chłodniczy</p>	<p>Siłowniki i silniki hydrauliczne</p>
		
<p>Pojazd</p>	<p>Śmieciarka Rotopress</p>	<p>Śmieciarka przedniozaładowcza</p>
<p>Odbiór mocy</p>	<p>Pompa hydrauliczna</p>	<p>Pompa hydrauliczna</p>
<p>Element wykonawczy</p>	<p>Silnik hydrauliczny oraz siłowniki hydrauliczne</p>	<p>Siłowniki hydrauliczne</p>

2.2. Realizacja funkcji zabudowy i obciążenie układu

W przeważającej liczbie przypadków, funkcje zabudowy realizowane są przy użyciu układu hydraulicznego. Dodatkowe wykorzystanie silnika spalinowego sprowadza się do napędu pompy hydraulicznej, odpowiedzialnej za dostarczanie żądanej ilości oleju do elementów wykonawczych układu w założonym czasie. Elementami wykonawczymi mogą być silniki hydrauliczne przekształcające energię hydrauliczną na energię ruchu obrotowego (parametry M i ω); lub siłowniki hydrauliczne, generujące ruch posuwisty tłoczyka z odpowiednią siłą (parametry F i V). W tym miejscu należy zaznaczyć, iż wielkości ω oraz V są parametrami istotnymi dla użytkownika, a przez to nastawialnymi. Spowodowane jest to żądanym czasem lub prędkością realizacji funkcji. Zwykle dąży się do jak najszybszego wykonania danej operacji w celu zwiększenia efektywności pracy maszyny, jednak ograniczeniem są w tym wypadku względy bezpieczeństwa obsługi oraz nadmierne naprężenia w konstrukcji spowodowane obciążeniami dynamicznymi lub nadmierne zużycie elementów maszyny. Zatem prędkość realizacji funkcji jest kompromisem między efektywnością a bezpieczeństwem i wytrzymałością maszyny.

Przykładem takiej pracy jest opróżnianie pojemników z odpadów przez mechanizm zasypowy śmieciarki zwany wrzutnikiem. Zadając większy przepływ oleju w układzie, ruch ramion wrzutnika mógłby odbywać się szybciej, jednak zbyt gwałtowny obrót opróżnianego pojemnika mógłby spowodować jego uszkodzenie, a nawet wypadnięcie z uchwytu. Ponadto, energia kinetyczna definiowana jest jako iloczyn masy i kwadratu prędkości. Zatem zwiększona 2-krotnie prędkość powoduje 4-krotny wzrost energii kinetycznej. Ta z kolei, w ogólnym przypadku, przy gwałtownym zatrzymaniu ramienia na odbijaczu zamieniana jest na energię sprężystości elementów. Skutkuje to 4-krotnie większym oddziaływaniem na konstrukcje tj. większymi naprężeniami w elementach konstrukcji.


W niektórych przypadkach czas realizacji funkcji narzucony jest arbitralnie i jest dłuższy niż minimalny wynikający z powyższych ograniczeń. Spowodowane jest to naturą pracy danej maszyny. Przykładem na to jest obracający się mieszalnik w betonomieszarce. Odpowiednio wysoka prędkość mieszalnika powoduje dodatkowe wymieszanie składników niezbędne do powstania gotowej mieszanki. W przypadku gdy pojazd został załadowany już gotową mieszanką w wytwórni betonu, prędkość obrotu mieszalnika jest ustawiona na niższą, w celu jedynie utrzymania jednorodności mieszanki w trakcie transportu.

Specyfika pracy oraz funkcja danego mechanizmu definiuje prędkość (kątową lub liniową), z jaką dany element wykonawczy powinien się poruszać. Z kolei parametry


M oraz F , są to wielkości wynikowe tzn. są efektem oporu jaki stawiany jest przed elementem wykonawczym, który dąży do pracy z zadaną prędkością. Zatem siła F w siłowniku hydraulicznym jest wynikiem oporu podczas wysuwania/wsuwania tłoczyska (np. podczas ruchu ramienia wrzutnika w śmieciarce), a moment M jest wynikiem momentu oporowego obracanego elementu (np. podczas obracania mieszalnika betonmieszarki). Podobnie w przypadku ciśnienia generowanego przez pompę hydrauliczną. Jest ono wynikiem obciążenia elementu wykonawczego i dostarczenia do niego wydatku oleju, który określony jest geometrią pompy i jej prędkością obrotową. Szersza analiza tego zjawiska opisana została w dalszej części pracy.

2.3. Odbiór mocy z silnika spalinowego na potrzeby zabudowy

W pojazdach samochodowych moc z silnika spalinowego podczas jazdy przekazywana jest z wału korbowego poprzez przekładnię wybieralną do dalszych elementów układu napędowego, kończąc na kołach pojazdu. Aby ten sam silnik napędzał elementy zabudowy pojazdu wymagane jest dodatkowe urządzenie, wykorzystujące moment obrotowy generowany przez silnik. Takim urządzeniem jest przystawka odbioru mocy (z ang. Power Take-Off (PTO)). Pojazd użytkowy może być wyposażony w różnorodne przystawki odbioru mocy, dostosowane do rodzaju urządzeń dodatkowych o zróżnicowanym zapotrzebowaniu mocy i zastosowaniach. Ze względu na sposób załączenia przystawki, rozróżnić można dwa typy: przystawki zależne od sprzęgła, używane podczas postoju pojazdu, oraz przystawki niezależne od sprzęgła, które mogą być używane zarówno podczas postoju, jak i w czasie jazdy.



Rys. 2.1. Przystawka odbioru mocy zależna od sprzęgła montowana z boku lub z tyłu skrzyni biegów [6].




Rys. 2.2. Przystawka zależna od sprzęgła montowana z tyłu skrzyni: 1-silnik, 2-skrzynia biegów, 3-główny wał, 4-pompa hydr., 5-przystawka [7].

2.3.1. Przystawki odbioru mocy zależne od sprzęgła


Przystawki tego typu są przeznaczone dla manualnych skrzyń biegów i mogą być używane tylko podczas postoju pojazdu. Typowe zastosowania to dźwigi samochodowe i wywrotki. Przystawki zależne od sprzęgła są mocowane z boku lub z tyłu skrzyni biegów i napędzane są od jej wałka pośredniego (Rys. 2.1, Rys. 2.2). Prędkość obrotowa i moment obrotowy przystawki zależą od prędkości obrotowej silnika i przełożenia przekładni stałej skrzyni biegów.

2.3.2. Przystawki odbioru mocy niezależne od sprzęgła

Przystawki tego typu mogą być napędzane za pośrednictwem automatycznej skrzyni biegów lub bezpośrednio od silnika. Typowe zastosowania to śmieciarki, betonomieszarki, samochody z nadwoziami chłodniczymi. Przystawki te mogą być włączane zarówno podczas postoju pojazdu, jak i w czasie jazdy. W automatycznej skrzyni biegów przystawka odbioru mocy jest napędzana od koła zamachowego silnika za pośrednictwem obudowy przekładni hydrokinetycznej. Jednak jej parametry robocze zależą wyłącznie od prędkości obrotowej silnika. W tym przypadku przystawkę mocuje się z boku lub u góry skrzyni biegów. Przystawkę odbioru mocy napędzaną od silnika mocuje się z tyłu jednostki napędowej. Napęd przystawki zapewnia mechanizm rozrzędu (Rys. 2.3, Rys. 2.4). Oznacza to, że przystawka jest załączona zawsze, gdy uruchomiony jest silnik.



Rys. 2.3. Przystawka odsilnikowa w pojeździe MAN [7].



Rys. 2.4. Przystawki odsilnikowe w pojazdach Mercedes-Benz. a) silnik OM936, maks. moment przystawki 650 Nm b) silnik OM470, maks. moment przystawki 600 Nm [8].

2.3.3. Zakres odbieranej mocy i parametry przystawki

Przystawkę odbioru mocy charakteryzują następujące parametry: kierunek obrotu, przełożenie, maksymalny moment obrotowy. Kierunek obrotu wałka przystawki jest istotny ze względu na montaż pompy hydraulicznej. Kierunek tłoczenia pompy musi być zgodny z kierunkiem obrotu przystawki, w przeciwnym wypadku może dojść do jej uszkodzenia. Przełożenie przystawki (r_{PTO}) określa stosunek prędkości kątowej wałka przystawki do prędkości kątowej silnika. Zazwyczaj r_{PTO} zawiera się w przedziale $0,8 \div 1,4$.

W zależności od rodzaju napędzanej zabudowy, przystawka może pracować w różnym zakresie mocy, od 10 kW do nawet 220 kW. Jako że prędkość obrotowa jest parametrem nastawialnym, przy doborze przystawki na etapie produkcji pojazdu należy zwrócić uwagę na ograniczenia konstrukcyjne w postaci maksymalnego momentu obrotowego z jakim przystawka może pracować. W Tabeli 2 przedstawiono przykładowe zapotrzebowanie na moc dla wybranych pojazdów użytkowych.

W cysternach do przewozu mleka przepływ jest niski, ponieważ mleko pompowane jest powoli. Zapotrzebowanie na moc wynosi ok. 10 kW. W przypadku cystern do przewozu chemikaliów wielkość przepływu zależy od lepkości przewożonej cieczy. Może to być olej, benzyna, nafta lub inne ciecze. Zapotrzebowanie na moc w urządzeniach tego typu wynosi 20–30 kW. W wywrotkach układ hydrauliczny wyposażony jest w jednostronnie działający siłownik hydrauliczny, napędzany za pomocą pompy hydraulicznej, a opróżniany grawitacyjnie poprzez nacisk zabudowy. Przystawka odbioru mocy wykorzystywana jest w krótkich okresach, a zapotrzebowanie na moc wynosi 20÷60 kW. W chłodniach chłodzenie przestrzeni ładunkowej odbywa się za pomocą agregatu chłodniczego napędzanego generatorem 380 V lub oddzielnym silnikiem. Generator napędzany jest przez układ transmisyjny silnika bezpośrednio lub za pośrednictwem pompy zmiennoprzepływowej. Zapotrzebowanie na moc wynosi 20 kW. W zamiatarko-zmywarkach występuje zróżnicowane zapotrzebowanie na moc w zależności od tego, czy pojazd jest wyposażony tylko w agregat ssący, czy zarówno w agregat ssący, jak i wysokociśnieniowy agregat spłukujący. Ponadto często występuje zapotrzebowanie na dodatkową moc w celu pochylenia zbiornika lub manewrowania ciężkimi włączami i bębniami, na które nawinięte są węże. Zapotrzebowanie na moc w przypadku agregatu ssącego wynosi 30÷80 kW, podczas gdy agregat spłukujący wymaga ok. 110 kW. W betonomieszarkach, które występują zwykle w pojemnościach 4-10 m³, zapotrzebowanie na moc waha się w granicach 40÷90 kW. Betonomieszarka pracuje wykorzystując dwa poziomy mocy: wyższy przy opróżnianiu, niższy przy obracaniu bębna w czasie transportu. Pompy do tłoczenia betonu wymagają dużej mocy,

do 160 kW, a w wyjątkowych przypadkach nawet do 220 kW. Moc powyżej 100 kW wymaga rozdzielczej skrzyni biegów.

Tabela 2. Orientacyjne zapotrzebowanie na moc w wybranych pojazdach użytkowych.


Cysterna do przewozu mleka	10 kW
Cysterna do przewozu chemikaliów	20 ÷ 30 kW
Wywrotka	20 ÷ 60 kW.
Chłodnia	20 kW
Zamiatarko-zmywarka	30 ÷ 80 kW + 110 kW.
Betonomieszarka	40 ÷ 90 kW
Pompa do tłoczenia betonu	160 ÷ 220 kW
Śmieciarka	5 – 50 kW

2.4. Podstawy działania śmieciarek


Część badawcza niniejszej pracy dotyczy analizy silnika spalinowego śmieciarki, toteż konieczne jest krótkie wprowadzenie na temat podstaw jej działania. Obszerny opis elementów składowych śmieciarki, wyposażenia dodatkowego i stosowanych systemów usprawniających zbiórkę odpadów zawarty został w pracach Borkowskiego [9]. Szczegółowy opis konstrukcji i problemów eksploatacyjnych omówiony został w rozprawie doktorskiej Czyżewicza [10].

Śmieciarka jest to pojazd przystosowany do zbiórki odpadów komunalnych i wywozu ich na miejsce składowania lub utylizacji. Najczęściej spotykanym typem jest śmieciarka tylnozaladowcza. Jej elementami charakterystycznymi (Rys. 2.5) są skrzynia ładunkowa (2) z płytą wypychającą (1), mechanizm zasypowy (6) oraz mechanizm prasujący (5). Ponadto wyróżnić można również odbijacz pojemników (4), który pełni zwykle także funkcję otwieracza większych pojemników. Trzy ostatnie elementy znajdują się w tylnej części zabudowy, zwanej odwłokiem (3). Aby opróżnić skrzynię ładunkową na wysypisku, odwłok podnosi się a ściana wypychająca wysuwa się. Elementami odpowiedzialnymi za ruch mechanizmów są najczęściej siłowniki hydrauliczne, rzadziej silniki hydrauliczne.

Najbardziej energochłonnym procesem podczas pracy zabudowy jest zagęszczanie odpadów przez mechanizm prasujący. Sekwencja ruchów mechanizmu przedstawiona na Rys. 2.6 polega na zagarnięciu odpadów z wanny zasypowej w odwłoku i ich przemieszczenie z jednoczesnym zagęszczeniem do skrzyni ładunkowej. Gdy mechanizm w końcowej fazie ruchu napotka wystarczająco wysoki opór, który oznacza że odpady są wystarczająco zagęszczone, ściana wypychająca przesuwana jest o kilka centymetrów w stronę kabiny kierowcy.



Rys. 2.5. Zabudowa śmieciarki w przekroju [11].



Rys. 2.6. Schemat działania mechanizmu zagęszczającego odpady [12].

Z punktu widzenia eksploatacji silnika spalinowego w celu realizacji powyższych funkcji należy zwrócić uwagę na punkty pracy, w jakich silnik się w tym czasie znajduje. Podczas pracy zabudowy silnik może pracować z prędkością biegu jałowego (zwykle 600 obr/min) lub z wyższą prędkością ustawianą na etapie produkcji śmieciarki ($900 \div 1050 \text{ obr/min}$). Gdy pojazd zatrzymuje się (i pozostaje na biegu jałowym), operator aktywuje przepływ oleju w układzie hydraulicznym. Mimo niskich obrotów, przepływ i podaż mocy są wystarczające aby operować mechanizmem zasypowym i opróżnić niewielkie pojemniki. W momencie aktywowania mechanizmu prasującego konieczne jest podniesienie prędkości obrotowej, zarówno z powodu konieczności zwiększenia przepływu jak i przede wszystkim zwiększenia dostępnej mocy. Podczas zagęszczania odpadów przy zbyt niskiej prędkości obrotowej ($600 - 700 \text{ obr/min}$), nagły wzrost obciążenia mógłby spowodować zdławienie, a w konsekwencji zgaszenie silnika. Dokładna wartość do jakiej zwiększana jest prędkość zależy od zastosowanej pompy hydraulicznej i przełożenia przystawki odbioru mocy.

Wyjściowym parametrem, który interesuje użytkownika jest czas pojedynczego cyklu mechanizmu prasującego t_{cykl} . Czas cyklu, a więc sekwencji ruchów mechanizmu zależy od wielkości zastosowanych siłowników oraz przepływu oleju w układzie. Aby wykonać określony ruch należy dostarczyć do siłownika odpowiednią objętość oleju V . W przypadku wysuwania tłoczyska V określona jest wzorem:

$$V = \frac{D^2 \pi}{4} \cdot L \quad (2.1)$$

a w przypadku wsuwania tłoczyska:

$$V = \frac{(D^2 - d^2) \pi}{4} \cdot L \quad (2.2)$$

Gdzie D oznacza średnicę tłoka, d średnicę tłoczyska, a L skok siłownika.

Objętość oleju definiowana jest również za pomocą przepływu Q w czasie t :

$$V = Q \cdot t \quad (2.3)$$

Z kolei przepływ oleju zależny jest od wydajności jednostkowej pompy q , przełożenia przystawki odbioru mocy r_{PTO} oraz prędkości obrotowej silnika n_{sil} :

$$Q = \eta \cdot q \cdot r_{PTO} \cdot n_{sil} \quad (2.4)$$

Gdzie η jest sprawnością objętościową pompy.

Zatem żądany czas wysuwu siłownika określony jest wzorami:

$$t = \frac{V}{Q} \quad (2.5)$$

$$t = \frac{D^2 \pi \cdot L}{4} \cdot \frac{1}{\eta \cdot q \cdot r_{PTO} \cdot n_{sil}} \quad (2.6)$$


Po przekształceniu równania 2.6 otrzymujemy prędkość obrotową n_{sil} z jaką powinien pracować silnik spalinowy:

$$n_{sil} = \frac{D^2 \pi \cdot L}{4 \cdot \eta \cdot q \cdot r_{PTO}} \cdot \frac{1}{t} \quad (2.7)$$

Typowy mechanizm prasujący w śmieciarce tylnozładowniczej wyposażony jest w 2 pary siłowników hydraulicznych. Pierwsza odpowiada za zgarnianie odpadów w wannie zasypowej, a druga za ruch mechanizmu w górę i w dół (Rys. 2.7). Geometrię siłowników w parze 1 określają średnica tłoka D_1 , średnica tłoczyska d_1 oraz skok L_1 , a w parze 2 odpowiednio D_2 , d_2 i L_2 .

Pełen cykl składa się 4 etapów:

- wsunięcie tłoczek pary 1
- wsunięcie tłoczek pary 2 – ruch prasy w dół
- wysunięcie tłoczek pary 1 – zagarnięcie odpadów
- wysunięcie tłoczek pary 2 – zagęszczenie odpadów i przemieszczenie ich do skrzyni ładunkowej



Rys. 2.7. Cykl pracy mechanizmu prasującego realizowany przy użyciu 2 par siłowników hydraulicznych [10].

Na żądany czas cyklu pracy t_{cykl} składa się suma czasów czterech etapów:

$$t_{cykl} = t_a + t_b + t_c + t_d \quad (2.8)$$

W każdym etapie należy dostarczyć do siłowników wykonujących ruch odpowiednią objętość oleju:

$$V_a = 2 \cdot \frac{(D_1^2 - d_1^2)\pi}{4} \cdot L_1 \quad (2.9)$$

$$V_b = 2 \cdot \frac{(D_2^2 - d_2^2)\pi}{4} \cdot L_2 \quad (2.10)$$

$$V_c = 2 \cdot \frac{D_1^2 \pi}{4} \cdot L_1 \quad (2.11)$$

$$V_d = 2 \cdot \frac{D_2^2 \pi}{4} \cdot L_2 \quad (2.12)$$

Łącząc równania 2.6, 2.8 i 2.9-2.12 otrzymujemy:

$$t_{cykl} = \pi \cdot \left(\left(D_1^2 - \frac{d_1^2}{2} \right) \cdot L_1 + \left(D_2^2 - \frac{d_2^2}{2} \right) \cdot L_2 \right) \cdot \frac{1}{\eta \cdot q \cdot r_{PTO} \cdot n_{sil}} \quad (2.13)$$

W rezultacie prędkość obrotowa n_{sil} z jaką powinien pracować silnik spalinowy aby zrealizować cykl w czasie t_{cykl} określa formuła:

$$n_{sil} = \pi \cdot \left(\left(D_1^2 - \frac{d_1^2}{2} \right) \cdot L_1 + \left(D_2^2 - \frac{d_2^2}{2} \right) \cdot L_2 \right) \cdot \frac{1}{\eta \cdot q \cdot r_{PTO}} \cdot \frac{1}{t_{cykl}} \quad (2.14)$$

Należy w tym miejscu zaznaczyć, iż prędkość n_{sil} nie jest jedynie wartością wynikową. Producent ma na nią realny wpływ poprzez odpowiednią konfigurację układu napędowego, tj. doboru przystawki o odpowiednim przełożeniu oraz stosowanie pompy hydraulicznej o odpowiedniej pojemności. Zatem ten sam czas cyklu t_{cykl} może być osiągnięty w szerokim zakresie n_{sil} , przy różnych konfiguracjach przystawka-pompa. Co więcej, konfiguracje mogą w ten sposób różnić się pod względem zapotrzebowania na energię konieczną do wykonania cyklu roboczego. Zagadnienie optymalnej konfiguracji układu napędowego oraz uzyskiwanie koniecznej do tego celu charakterystyki silnika spalinowego omówione są w dalszej części pracy (rozdział 11).

2.5. Rodzaje połączenia przystawki z pompą stosowane w śmieciarkach


W większości podwozi, na których montowane są zabudowy śmieciarek, przystawka odbioru mocy umieszczona jest na bloku przekładni hydrokinetycznej, odbierając moment z koła zamachowego. Jeśli wymiary pompy hydraulicznej na to pozwalają, preferowany jest bezpośredni montaż pompy do przystawki. Zaletą tego rozwiązania jest prostota, niski koszt oraz łatwy dostęp serwisowy. Niestety niewielka odległość od silnika powoduje wyższą temperaturę pracy pompy, co może negatywnie wpłynąć na jej trwałość oraz przyspieszyć proces starzenia oleju. Alternatywny montaż polega na użyciu wału homokinetycznego (Rys. 2.8). W powyższych rozwiązaniach pompa połączona jest na stałe z silnikiem, co oznacza jej ciągłą pracę równoległą z pracą silnika. Jest to zjawisko niepożądane z energetycznego punktu widzenia, z uwagi na straty w układzie hydraulicznym. Rozwiązanie, które ma na celu zminimalizowanie tych strat



to tzw. by-pass, czyli zastosowanie krótkiego obiegu hydraulicznego. Jego działanie polega na przepływie oleju z pompy jedynie przez umieszczony w niewielkiej odległości rozdzielacz, prosto do zbiornika. Aktywacja zabudowy zmienia nastawę rozdzielacza i przełącza układ hydrauliczny z krótkiego obiegu na obieg właściwy, co jest swojego rodzaju „włączeniem zabudowy”. W krótkim obiegu olej tłoczony jest pod minimalnym ciśnieniem (maks. 20 bar).

Pomiędzy wałem homokinetycznym a pompą stosowane może być sprzęgło elektromagnetyczne, które umożliwia włączenie i wyłączenie pompy przez operatora niezależnie od silnika. W niektórych przypadkach dodatkowym elementem powyższego zestawu jest również tłumik drgań. Zastosowanie sprzęgła przynosi korzyści w postaci niższego zużycia paliwa, jednak cena zestawu jest znacznie wyższa od pompy montowanej bezpośrednio, zatem wybór powinien być ekonomicznie uzasadniony.

Przystawki umieszczone na skrzyni biegów pozwalają na włączanie/wyłączanie pompy, a przez to niższe zużycie paliwa. Wadą takiego rozwiązania jest trudniejszy montaż oraz dostęp serwisowy.



Rys. 2.8. Przystawka odbioru mocy (1) z pompą (2) montowaną poprzez wał homokinetyczny (3), sprzęgło elektromagnetyczne (4) oraz tłumik drgań (5).

3. UKŁAD NAPĘDOWY POJAZDU UŻYTKOWEGO

W tym rozdziale przedstawiono układ napędowy pojazdu użytkowego w postaci modelu wykonanego przy pomocy metody Grafów Wiązań. Omówiona została procedura, dzięki której uzyskiwany jest model oraz jego ogólne zastosowanie przy obliczaniu sprawności energetycznej układu. Ponadto przedstawiony został proponowany przez autora szczegółowy model układu napędowego śmieciarki. Model umożliwia określenie sprawności poszczególnych procesów zachodzących podczas pracy zabudowy oraz pozwala na analizę układu pod kątem minimalizacji strat energetycznych.

3.1. Wstęp do metody Grafów Wiązań


Jednym ze sposobów graficznej reprezentacji modelu systemu energetycznego jest metoda Grafów Wiązań (GW, lub z ang. Bond Graphs (BG)). Po raz pierwszy została ona opisana przez Payntera [13], a następnie rozwijana w wielu monografiach i publikacjach, m.in. w [4,5,14,15]. Metoda ta charakteryzuje się jednolitym podejściem do modelowania elementów o różnej naturze fizycznej. Szczególnie przydatna jest do modelowania systemów energetycznych składających się z elementów cieplnych, mechanicznych i hydraulicznych, a zatem takich jakie występują w układzie napędowym analizowanego w niniejszej pracy pojazdu.

W metodzie GW przepływ energii pomiędzy elementami systemu energetycznego reprezentowany jest przez grafy (półstrzałki), które jednocześnie informują o kierunku tego przepływu. Dodatkowo przepływ energii opisany jest zawsze parą zmiennych: uogólnionym potencjałem e , oraz uogólnionym przepływem f . Ogólnie przyjętą konwencją jest oznaczanie e nad grafem, a f pod grafem. Przykładami przepływu energii w układzie napędowym pojazdu użytkowego są przepływy energii: ruchu obrotowego, ruchu posuwistego, energii hydraulicznej. Ich reprezentacja w konwencji GW wraz z równaniami przedstawione są w Tabeli 3. Iloczyn dwóch parametrów energetycznych (e i f) w GW zawsze ma wymiar mocy.

Oprócz grafów, model opisany metodą GW składa się z elementów zewnętrznych: S (źródło energii), L (akumulator energii kinetycznej), C (akumulator energii potencjalnej), R (element dyssypacyjny) oraz elementów wewnętrznych: przetworników energii, węzłów 0 o jednakowym uogólnionym potencjale oraz węzłów 1 o jednakowym uogólnionym przepływie. Źródła energii w modelowanym systemie mogą występować w dwóch postaciach: jako źródło potencjału: SE (uogólniony potencjał jest niezależną funkcją czasu) lub jako źródło przepływu: SF (uogólniony przepływ jest niezależną funkcją czasu).

Tabela 3. Reprezentacja przepływu energii wg GW.

Rodzaj przepływu	Przepływ w konwencji GW
Przepływ energii w ogólności	
Przepływ energii ruchu obrotowego $\dot{E}_o = M \cdot \omega_o$	
Przepływ energii hydraulicznej $\dot{E}_h = p \cdot Q$	
Przepływ energii ruchu posuwistego $\dot{E}_p = F \cdot V$	



Rys. 3.1. Schemat i oznaczenia modelu GW systemu energetycznego do określania sprawności. (e - uogólniony potencjał, f - uogólniony przepływ, p - uogólniony pęd, q - uogólnione przemieszczenie) [5].

Określenie sprawności energetycznej systemu w konwencji GW wymaga wyodrębnienia grafów charakteryzujących energię użyteczną R_e oraz energię strat R_{str} . Energia użyteczna może być reprezentowana przez elementy dysypacyjne lub akumulatory energii. Sprawność chwilową systemu energetycznego przy założeniu, że pracuje on w stanach ustalonych tj.:

$$e_s f_s = e_e f_e + e_{str} f_{str} \quad (3.1)$$

wyznaczają się z zależności [4]:

$$\eta_o = \frac{e_e f_e}{e_s f_s} \quad (3.2)$$

Chwilowa sprawność ogólna jest zależna od ustalonego wektora sterowania, od którego zależą strumienie energii doprowadzanej do systemu i energii użytecznej. Wiele systemów energetycznych, jak na przykład pojazd, funkcjonuje najczęściej w stanach nieustalonych. Wprowadza się pojęcie sprawności eksploatacyjnej [4],

określającej sprawność systemu w czasie t_{ex} . Przy ocenie energetycznej sprawności systemu powinna być uwzględniona akumulacja energii.

Energia potencjalna ΔE_C i kinetyczna ΔE_L akumulowana w systemie nie zależy od przebiegu akumulacji w czasie $t \in (0, t_{ex})$, lecz od stanu początkowego i końcowego, to znaczy:

$$\Delta E_C = \int_0^{t_{ex}} e_c \dot{q}_c dt = E_C(t_{ex}) - E_C(0) \quad (3.3)$$

$$\Delta E_L = \int_0^{t_{ex}} \dot{p}_c f_c dt = E_L(t_{ex}) - E_L(0) \quad (3.4)$$

Sprawność eksploatacyjna wyrażona jest zależnością [4]:

$$\eta_{ex} = \frac{\int_0^{t_{ex}} e_e f_e dt + \Delta E_C + \Delta E_L}{\int_0^{t_{ex}} e_s f_s dt} \quad (3.5)$$

3.2. Układ napędowy pojazdu użytkowego w konwencji Grafów Wiązań

3.2.1. Schemat blokowy

Opisana w poprzedniej sekcji metoda GW umożliwia budowę modelu systemu energetycznego w sposób graficzny, który przy analizie istniejącego już obiektu jest bardziej intuicyjny. Analizę obiektu można rozpocząć od ogólnego schematu blokowego przepływu energii, który dla pojazdu użytkowego wyposażonego w układ hydrauliczny przedstawiony jest na Rys. 3.2.


W działającej maszynie analizę najłatwiej rozpocząć od rozpoznania elementu wykonawczego, odpowiedzialnego za ruch w mechanizmie zabudowy pojazdu użytkowego. Następnym krokiem jest rozpoznanie źródła przepływu energii dla tego elementu, w tym przypadku jest to pompa hydrauliczna. Ta z kolei napędzana jest przez silnik spalinowy pojazdu, dla którego źródłem energii jest paliwo ze zbiornika.



Rys. 3.2. Schemat blokowy przepływu energii w pojeździe użytkowym.

3.2.2. Bazowy model układu napędowego w konwencji Grafów Więzań

Powyższy schemat należy przekształcić w model w konwencji GW (Rys. 3.3) na podstawie dokładnej znajomości budowy układu napędowego i procesów w nim zachodzących.



Rys. 3.3. Uproszczony model układu napędowego pojazdu użytkowego z jednym elementem wykonawczym.

Rozpoczynając analizę układu od elementu wykonawczego, energia użyteczna R_{es} rozpraszana jest przez siłownik hydrauliczny SH , który wysuwając się z wymaganą przez wykonywaną funkcję prędkością V_S , działa na elementy mechanizmu z siłą F_S . Podczas jego ruchu część energii R_{SH} rozpraszana jest na skutek oporów ruchu siłownika. Strumień energii hydraulicznej, definiowanej iloczynem ciśnienia P_P oraz wydatku oleju Q_P , dostarczany jest do siłownika przez pompę hydrauliczną PH . Pompa przetwarza w strumień energii hydraulicznej, strumień energii ruchu obrotowego opisanego momentem obrotowym na wałku pompy M_P i prędkością kątową wałka ω_P . Straty objętościowe oraz straty ciśnienia podczas tego procesu reprezentowane są przez element dyssypacyjny R_{PH} . Ruch obrotowy pochodzi z przystawki odbioru mocy (PTO – Power Take-Off). Niewielkie straty mechaniczne w przystawce, typowe dla przekładni zębatych, reprezentowane są przez element dyssypacyjny R_{PTO} . Przystawka odbiera strumień energii z silnika spalinowego SS , którego koło zamachowe obraca się z prędkością ω_S . Stosunek prędkości ω_{PTO}/ω_O określony jest przez przełożenie przystawki (r_{PTO}). Silnik generuje moment obrotowy M_S . Źródłem strumienia energii dostarczanej do silnika jest zbiornik paliwa ZP . Jest to źródło o stałym potencjale W_d – wartości opałowej oleju napędowego. Wartością zmienną w czasie jest masowy strumień paliwa G_e . Straty w termodynamicznych procesach zamiany energii chemicznej paliwa na mechaniczną w silniku spalinowym oraz straty spowodowane napędem urządzeń pomocniczych silnika reprezentowane są jedną ogólną wielkością R_{SS} .

Na podstawie schematu, model układu napędowego w konwencji GW umożliwia w łatwy sposób formułowanie równań przepływu energii, w zależności od obserwowanego zjawiska. Rozważając pojedynczy węzeł lub połączoną grupę węzłów

suma strumieni energii grotów źródeł musi być równa sumie strumieni energii grotów wychodzących. Uzyskane równanie przepływu energii w łatwy sposób prowadzi do informacji o sprawności przetwornika:

$$W_d G_e = M_S \omega_S + R_{SS} \rightarrow \eta_{SS} = \frac{M_S \omega_S}{W_d G_e} = \frac{M_S \omega_S}{M_S \omega_S + R_{SS}} \quad (3.6)$$

$$M_S \omega_S = M_P \omega_P + R_{PTO} \rightarrow \eta_{PTO} = \frac{M_P \omega_P}{M_S \omega_S} = \frac{M_P \omega_P}{M_P \omega_P + R_{PTO}} \quad (3.7)$$

$$M_P \omega_P = p_P Q_P + R_{PH} \rightarrow \eta_{PH} = \frac{p_P Q_P}{M_P \omega_P} = \frac{p_P Q_P}{p_P Q_P + R_{PH}} \quad (3.8)$$

Analizując zestaw złożony z kilku węzłów liczba elementów dyssypacyjnych naturalnie wzrośnie. Dla zestawu ZP-PTO równanie bilansu mocy ma postać:

$$W_d G_e = M_P \omega_P + R_{SS} + R_{PTO} \quad (3.9)$$

Iloczyn momentu i prędkości kątowej jest w tym wypadku strumieniem energii użytecznej. Sprawność chwilowa takiego zestawu określona jest przez:

$$\eta_{ZP-PTO} = \frac{M_P \omega_P}{W_d G_e} = \frac{M_P \omega_P}{M_P \omega_P + R_{SS} + R_{PTO}} \quad (3.10)$$

Analogicznie, przepływ energii w zestawie SS-SH opisuje równanie:

$$M_S \omega_S = F_S V_S + R_{PTO} + R_{PH} + R_{SH} \quad (3.11)$$


A sprawność chwilowa równa jest:

$$\eta_{SS-SH} = \frac{F_S V_S}{M_S \omega_S} = \frac{F_S V_S}{F_S V_S + R_{PTO} + R_{PH} + R_{SH}} \quad (3.12)$$

Należy zaznaczyć, iż możliwy jest dowolny poziom szczegółowości opisu zjawisk za pomocą metody GW. Straty R_{PH} podczas pracy pompy można podzielić na straty ciśnieniowe oraz objętościowa, które zależą odpowiednio od wydatku oleju i od ciśnienia pracy. Analogicznie, na straty R_{SS} składają się strumień ciepła przekazywany ściankom komory roboczej, strumień energii odprowadzanej w procesie wylotu, tarcie między komponentami silnika, napęd urządzeń pomocniczych silnika (np. wałki rozrządu, alternator) itd. O poziomie szczegółowości modelu decyduje cel jego wykonania oraz zakładany efekt analizy. Z inżynierskiego punktu widzenia, należy również wziąć pod uwagę możliwości aparatury pomiarowej. Model powinien być opisany przez parametry relatywnie proste do zaobserwowania i zmierzenia.

3.3. Układ napędowy śmieciarki

W tym podrozdziale omówiony został szczegółowy model układu napędowego śmieciarki, przy wykorzystaniu metody GW. Dzięki niemu możliwa jest analiza przepływu strumienia energii począwszy od zbiornika paliwa aż do poszczególnych elementów wykonawczych, z uwzględnieniem strat. Według wiedzy autora, jest to pierwsze tak szczegółowe przedstawienie modelu przepływu energii w śmieciarce. Późniejsza analiza sprawności układu jest analizą autorską.



Rys. 3.4. Model układu napędowego śmieciarki (opis w tekście).

Model przedstawiony na Rys. 3.4 jest rozwinięciem modelu z Rys. 3.3. Strumień energii z przystawki odbioru mocy **PTO** kierowany jest do dwusekcyjnej pompy hydraulicznej **PH2S**. Ten typ pompy jest często stosowany w śmieciarkach, ponieważ układ hydrauliczny podzielony jest na dwa obiegi: tzw. duży i mały obieg. Duży obieg wymaga większego przepływu oleju ponieważ odpowiedzialny jest za napęd mechanizmu prasującego. Mały obieg napędza mechanizm zasypowy (wrzutnik), który wyposażony jest w znacznie mniejsze siłowniki, przez co wymaga mniejszej ilości oleju. Zatem w tym miejscu strumień energii rozdziela się pomiędzy dwa obiegi, napędzane przez osobne sekcje pompy. Niewielka część energii rozpraszana jest w postaci R_{p1} i R_{p2} , odpowiednio dla sekcji nr 1 i 2, w zależności od sprawności pompy. Olej hydrauliczny tłoczony z sekcji 1 i 2 trafia odpowiednio do dużego i małego obiegu w ilości Q_1 i Q_2 oraz pod ciśnieniem p_1 i p_2 . Z uwagi na budowę układu hydraulicznego konieczne jest uwzględnienie miejscowych i liniowych strat ciśnienia. Generowany przez zawory i rury opór powoduje wzrost temperatury oleju. Rozproszona w postaci ciepła część energii reprezentowana jest w modelu przez R_{uh1} i R_{uh2} .

Końcowym elementem hydraulicznym dużego obiegu jest siłownik prasy **SP**, do którego olej dociera pod ciśnieniem p_{SP} . Strumień energii hydraulicznej zamieniany jest na przepływ energii ruchu posuwistego opisanego przez prędkość ruchu V_{SP} oraz siłę oporu F_{SP} , jaką należy pokonać podczas ruchu siłownika. Część mocy hydraulicznej rozpraszana jest na pokonanie oporów własnych siłownika R_{SP} , spowodowanych tarciem podczas wysuwania/wsuwania tłoczyska (m.in. tarcie uszczelnienia o tłoczysko). Siła F_P użyta do zagęszczania odpadów jest mniejsza od F_{SP} na skutek konieczności pokonania oporów ruchu mechanizmu R_{TP} , spowodowanych tarciem m.in. klocków ślizgowych o prowadnicę mechanizmu, oraz tarciem występującym w sworzniach. Podczas zagęszczania odpadów prasa przemieszcza się z wanny w górę, w stronę dachu skrzyni załadowniczej. Następuje zatem jej wzrost energii potencjalnej R_{hp} , jednak stanowi ona znikomy procent w bilansie przepływu energii. Wreszcie, strumień energii dostarczony z sekcji nr 1, po uwzględnieniu strat, zamieniany jest na pracę użyteczną R_{ep} , wykonaną do zagęszczenia odpadów. Należy w tym miejscu zaznaczyć, iż proces zagęszczania odpadów jest bardzo skomplikowany i trudny pod względem opisu przemian energetycznych w nim zachodzących. W trakcie pracy mechanizmu, odpady są zagęszczane oraz przemieszczane z wanny do skrzyni ładunkowej. Występuje przy tym tarcie śmieci o stalowe powierzchnie elementów zabudowy, oraz tarcie wewnętrzne pomiędzy odpadami. Część rozproszonej w ten sposób energii przyczynia się do wstępnego zagęszczenia, jednak dokładna proporcja jest niemożliwa do określenia. Dodatkowo odpady transportowane są z wanny poniżej skrzyni, zatem następuje ich

niewielki wzrost energii potencjalnej. Właściwe zagęszczanie odbywa się na skutek ruchu mechanizmu prasującego oraz oporowi jaki stawiają ściany skrzyni ładunkowej oraz płyta wypychająca. Ta ostatnia jest elementem ruchomym, który wraz ze wzrostem ilości zagęszczonych odpadów w tylnej części skrzyni, przemieszcza się w stronę kabiny kierowcy, przy czym odbywa się to nie w każdym cyklu mechanizmu. Umożliwia to utrzymywanie dużego oporu przy jednoczesnym zwiększaniu przestrzeni zajmowanej przez odpady w skrzyni. Warto zauważyć, że już przy niewielkim wypełnieniu skrzyni, mechanizm prasujący wypychając nowe odpady do skrzyni, musi przesunąć dotychczasową ich objętość oraz płytę wypychającą. Zatem pewna część energii przeznaczona jest na pokonanie tarcia odpadów w skrzyni oraz oporów ruchu płyty wypychającej. Jedynymi pozycjami w literaturze opisującymi proces zagęszczania odpadów są prace J.Czyżewicza [10,16]. Dokładne proporcje w jakich dzieli się R_{eP} wciąż jednak nie są znane, i stanowią niewątpliwie kierunek dalszych badań nad procesem zagęszczania odpadów i jego optymalizacji energetycznej.

Kończącym elementem hydraulicznym małego obiegu jest siłownik wrzutnika SW , do którego olej dociera pod ciśnieniem p_{SW} . Podobnie jak SP , wykonuje one ruch posuwisty z prędkością V_{SW} oraz siłą F_{SW} . Opory własne siłownika uwzględnione są w postaci R_{SW} . Tarcie w elementach mechanizmu zasypowego reprezentuje wielkość R_{TW} . W rezultacie efektywną siłą, z jaką wrzutnik wraz z pojemnikiem z odpadami podnoszony jest siłą F_W . Zadaniem mechanizmu zasypowego jest podniesienie pojemnika ponad krawędź zasypową zabudowy, obrócenie go i wysypanie odpadów do wanny. Praca wykonana przez siłownik sprowadza się do wzrostu energii potencjalnej zestawu: wrzutnik-pojemnik-odpady. Zatem dzieli się ona na przyrost energii potencjalnej wrzutnika R_{hW} , pojemnika R_{hPoj} i odpadów R_{eO} . Warto zauważyć, że jedynie R_{eO} jest efektywną pracą z punktu widzenia zbiórki odpadów. Często zdarza się, że masa odpadów w opróżnianych pojemnikach jest stosunkowo niewielka (szczególnie w przypadku odpadów z tworzyw sztucznych) w porównaniu z masą pojemnika i wrzutnika. W takiej sytuacji, energia poświęcona na ruch zestawu w większości przeznaczona jest na R_{hW} i R_{hPoj} . Analogicznie, w przypadku opróżniania dużych pojemników (a nawet kontenerów) stosunek masowy jest znacznie korzystniejszy, przez co R_{eO} stanowi większą część zużytej energii.

3.4. Analiza sprawności układu napędowego śmieciarki

Zaproponowany model pozwala w czytelny sposób przedstawiać przepływ energii w układzie napędowym śmieciarki począwszy od źródła energii w postaci zbiornika paliwa aż po elementy odpowiedzialne za energię użyteczną wykorzystaną

do zagęszczania odpadów i opróżniania pojemników. Model zwraca uwagę na elementy dyssypacyjne odpowiedzialne za straty w układzie, przez co stanowi model odniesienia w procesie optymalizacji całego układu pod kątem zużycia energii.

Analizując zależność pomiędzy masowym strumieniem paliwa G_e a efektywną pracą wykonaną przy zagęszczaniu odpadów R_{eP} , otrzymujemy:

$$W_d G_e = R_{SS} + R_{PTO} + R_{P1} + R_{uh1} + R_{SP} + R_{TP} + R_{hP} + R_{eP} + R_{P2} + p_2 Q_2 \quad (3.13)$$

Gdzie $p_2 Q_2$ odpowiada za energię dostarczoną do małego obiegu hydraulicznego. Pozwala to uzyskać wzór na sprawność procesu zagęszczania odpadów η_P przez mechanizm prasujący:

$$\eta_P = \frac{R_{eP}}{W_d G_e} = \frac{R_{eP}}{R_{SS} + R_{PTO} + R_{P1} + R_{uh1} + R_{SP} + R_{TP} + R_{hP} + R_{eP} + R_{P2} + p_2 Q_2} \quad (3.14)$$

Zależność pomiędzy G_e a efektywną pracą wykonaną przy opróżnianiu pojemników R_{eO} , określona jest wzorem:

$$W_d G_e = R_{SS} + R_{PTO} + R_{P2} + R_{uh2} + R_{SW} + R_{TW} + R_{hW} + R_{hP} + R_{eO} + R_{P1} + p_1 Q_1 \quad (3.15)$$

Sprawność procesu opróżniania pojemników η_O :

$$\eta_O = \frac{R_{eO}}{W_d G_e} = \frac{R_{eO}}{R_{SS} + R_{PTO} + R_{P2} + R_{uh2} + R_{SW} + R_{TW} + R_{hW} + R_{hP} + R_{eO} + R_{P1} + p_1 Q_1} \quad (3.16)$$

Mimo, iż efektywna praca przy zagęszczaniu odpadów R_{eP} jest pojęciem dość wirtualnym, w równaniu (η_P 14) można wskazać czynniki decydujące o sprawności procesu. Podobnie czynniki występują w równaniu (η_O 16). Niektóre z nich nie są zależne od użytkownika: R_{PTO} zależne od sprawności przystawki, R_{P1} i R_{P2} zależne od sprawności pompy oraz R_{SP} i R_{SW} zależne od konstrukcji siłowników. Pozostałe elementy równania mogą zostać w pewnym stopniu zredukowane. Zastosowanie zaworów i bloków hydraulicznych o mniejszych oporach przepływu mogłoby doprowadzić do zmniejszenia strat R_{uh1} i R_{uh2} . Klocki ślizgowe lub rolki stosowane w mechanizmie prasującym, czy też system ich smarowania mógłby zostać udoskonalony zmniejszając tym samym R_{TP} . Podobnie w przypadku mechanizmu zasypowego, opory ruchu R_{TW} zredukować można poprzez optymalizację tarcia pomiędzy tulejami i sworzniami, lub też innymi ruchomymi elementami mechanizmu. Energia związana ze zmianą wysokości na jakiej znajduje się prasa R_{hP} jest stosunkowo niewielka, a zmniejszanie jej masy prowadzące do redukcji R_{hP} prowadzi do wysoko niepożądanych skutków w postaci zmniejszenia wytrzymałości i trwałości mechanizmu.

3.5. Podsumowanie

Zarówno przedstawiona powyżej analiza sprawności układu napędowego jak i optymalne pod kątem zużycia paliwa konfigurowanie układu napędowego wymaga znajomości zależności pomiędzy prędkością obrotową silnika i momentem obrotowym a strumieniem paliwa: $G_e(n, M)$. Zależność ta zwana charakterystyką ogólną silnika, jest unikatowa dla danego silnika. Podstawowym problemem z punktu widzenia producentów zabudów pojazdów użytkowych jest fakt, iż charakterystyki silników nie są ogólnodostępne, przez co ich wykorzystanie jest bardzo ograniczone. Producenci silników spalinowych udostępniają charakterystyki ogólne tylko w wyjątkowych przypadkach. Wyznaczenie charakterystyk dysponując pojazdem ciężarowym przy użyciu konwencjonalnych metod, takich jak użycie hamowni silnikowej czy podwoziowej jest zupełnie nieopłacalne (w przypadku tej pierwszej) lub problematyczne pod względem logistycznym oraz również związane ze znacznymi kosztami (w przypadku tej drugiej).

Alternatywna metoda określania relacji $G_e(n, M)$, która eliminuje konieczność użycia specjalistycznej aparatury i stanowisk badawczych stanowiłaby rozwiązanie powyższych problemów. Jako że każde odwzorowanie jest pewnego rodzaju uproszczeniem modelowanego zjawiska, w celu inżynierskiego zastosowania metody konieczne jest określenie wymaganej dokładności. Na podstawie informacji uzyskanych od producenta pojazdów użytkowych, akceptowalny błąd symulowanego zużyciu paliwa nie powinien przekraczać 7%. Z dotychczas przeprowadzonych analiz taka dokładność umożliwia wykorzystanie modelu zarówno do analizy sprawności układu napędowego jak i jego optymalnej konfiguracji.

4. CEL I TEZA PRACY

Teza pracy:

Wykorzystując dane pomiarowe pochodzące z bieżącej eksploatacji pojazdów użytkowych możliwe jest odwzorowanie właściwości energetycznych silnika spalinowego celem prognozowania zużycia paliwa z dokładnością oczekiwaną przez konstruktorów takich pojazdów.

Cel pracy:

Celem pracy jest opracowanie modelu, który odwzorowuje właściwości energetyczne silnika spalinowego pojazdu użytkowego na podstawie danych z pomiarów trakcyjnych. Integralnym elementem modelu jest procedura selekcji danych pochodzących z pomiarów trakcyjnych ze względu na nierównomierny rozkład punktów pomiarowych w polu pracy silnika.


Uzyskany model ma umożliwić optymalizację, ze względu na zużycie paliwa, konfiguracji układu napędowego urządzeń wykonawczych pojazdów użytkowych oraz ocenę efektywności energetycznej różnych układów napędowych takich pojazdów (praca wykonywana na zlecenie firmy Ekocel – niskonakładowa optymalizacja układów roboczych śmieciarek przy użyciu danych eksploatacyjnych).

5. REJESTRACJA PARAMETRÓW PRACY POJAZDU

W rozdziale przedstawiony został sposób rejestracji danych trakcyjnych w pojeździe użytkowym. Omówione zostały podstawy działania magistrali CAN oraz sposób dekodowania danych uzyskanych z interfejsu FMS w formacie szesnastkowym na wartości poszczególnych parametrów pracy pojazdu. Ponadto przedstawiona została analiza wartości momentu obrotowego uzyskiwanego z FMS. Interpretacja jego wartości uzasadniona została w sposób teoretyczny przy użyciu modelu w formie Grafów Wiązań, a następnie poparta została wynikami dwóch testów przeprowadzonych na pojeździe ciężarowym.

5.1. Magistrala CAN w pojeździe ciężarowym

Rynek pojazdów ciężarowych oferuje szeroki wybór modeli. Każdy z producentów używa specjalnego i unikalnego dla siebie systemu komunikacji wewnątrz pojazdu. Komponenty elektroniczne połączone są ze sobą za pomocą szeregowej magistrali komunikacyjnej (z ang. Controller Area Network - CAN). Informacje przesyłane są między urządzeniami w formie komunikatów (ramek danych). Ramka danych zawiera identyfikator charakterystyczny dla danego urządzenia oraz samą informację. W magistrali CAN nie ma wyodrębnionej jednostki nadrzędnej, a komunikacja ma charakter rozgłoszeniowy ponieważ cyfrowe komunikaty nadawane na magistralę odbierane są przez wszystkie urządzenia. CAN charakteryzuje się dużą odpornością na zakłócenia i niezawodnością.



Rys. 5.1. Schemat sieci komunikacyjnej w pojeździe Mercedes-Benz (opis w tekście) [8].

Zwykle stosowanych jest kilka magistrali CAN połączonych ze sobą poprzez jednostkę centralną. Przykład struktury sieci w pojeździe marki Mercedes-Benz

przedstawiono na Rys. 5.1. W tym przypadku jednostka centralna łączy trzy magistrale: CAN 1, CAN 2 i CAN 3. **CAN 1** to magistrala zewnętrzna, do której poprzez moduł **A8** dostęp mają producenci zabudowy pojazdu. Umożliwia ona sterowanie niektórymi parametrami pojazdu na potrzeby realizacji funkcji zabudowy (np. zwiększenie prędkości obrotowej na czas pracy pompy hydraulicznej). Moduły urządzeń związanych z kabiną kierowcy połączone są magistralą **CAN 2**. Poszczególne urządzenia mogą być połączone z modułem za pomocą LIN (z ang. Local Interconnect Network), np. zestaw przycisków kierownicy (**LIN 7**), panel przycisków drzwiowych (**LIN 9**) itd. Dopiero moduł (np. **A16**, **A43**) podłączony jest do CAN. **CAN 3** odpowiada za połączenie z modułem wskaźników deski rozdzielczej **A1**.

Szczegółowy opis budowy i zasad funkcjonowania sieci wykracza poza zakres niniejszej pracy. W dalszej części skupiono się na zastosowaniu parametrów pracy pojazdu przez nią rejestrowanych. Dokładny opis magistrali CAN dostępny jest w wielu źródłach m.in. [17,18,19,20].

5.2. Standard FMS

Komunikacja między urządzeniami wewnątrz magistrali CAN oraz jej techniczne aspekty określone są przez standard SAE J1939 [21]. Definiuje on m.in. fizyczne parametry CAN oraz sposób i format przesyłania danych. W 2002 roku z inicjatywy największych producentów pojazdów ciężarowych został utworzony ujednoczony interfejs **FMS** (z ang. Fleet Management System) umożliwiający odczyt danych z pojazdu przez użytkowników. Dowolny pojazd ciężarowy może być wyposażony w FMS na etapie produkcji lub w późniejszym okresie użytkowania. Pozwala on na podłączenie do magistrali CAN i rejestrację danych, eliminując ryzyko jakiegokolwiek ingerencji w jej działanie. Dzięki ujednoczonemu protokołowi J1939, rejestrowane dane charakteryzują się wspólnym formatem dla dowolnej marki pojazdu. Wybrane parametry pracy pojazdu dostępne poprzez interfejs FMS przedstawiono w Tabeli 4.

Tabela 4. Parametry pracy silnika dostępne poprzez interfejs FMS.

Parametr	Nazwa wg FMS	Jednostka
Prędkość obrotowa silnika	<i>Engine speed</i>	obr/min
Moment obrotowy (% maksymalnego momentu silnika)	<i>Actual Engine – Percent Torque</i>	%
Strumień paliwa	<i>Fuel Rate</i>	dm ³ /h
Łączne zużycie paliwa	<i>Engine total fuel used</i>	L
Prędkość pojazdu	<i>Wheel Based Speed</i>	km/h

Temperatura cieczy chłodzącej silnik	<i>Engine Coolant Temperature</i>	°C
Numer identyfikacyjny pojazdu	<i>Vehicle Identification Number</i>	-
Przebyty dystans	<i>High resolution total vehicle distance</i>	km

5.3. Przetwarzanie danych

Zarejestrowane dane wymagają obróbki w postaci rozpoznania ramki komunikatu oraz przeliczenia wartości z poszczególnych bajtów na wartości parametrów wg dokumentacji FMS [22]. W Tabeli 5 przedstawiono fragment pliku zawierającego zarejestrowane dane z podwozia marki Scania. Zawierają one identyfikator ID, dane w formacie szesnastkowym oraz czas rejestracji. Poniżej przedstawiono metodykę przeliczania zarejestrowanych danych.

Analizując przykładowo wiersz nr 7 z powyższej tabeli, w pierwszej kolejności należy rozpoznać identyfikator ramki. F004 odpowiada ramce wysyłanej przez sterownik silnika (z ang. Electronic Engine Controller #1: EEC1). Fragment instrukcji z dokumentu [22] dla tej ramki przedstawiono na Rys. 5.2. Dalszy algorytm przeliczenia wartości prezentuje Rys. 5.3. Na bajt odpowiadający za informację o procentowym momencie obrotowym silnika składają się dwie liczby w formacie szesnastkowym. Obowiązuje zasada, że bit najbliższej prawej strony jest najbardziej znaczący, a więc odpowiada za najwyższą potęgę liczby 16. W praktyce oznacza to zamianę kolejności, zatem 8B przyjmuje postać równania $11 \cdot 16^1 + 8 \cdot 16^0 = 184$. Następnie od uzyskanej wartości należy odjąć 125%, aby otrzymać końcową wartość momentu obrotowego wyrażoną jako procentowa wartość maksymalnego momentu silnika. Analogicznie dla prędkości obrotowej, za którą odpowiadają bajty nr 4 i 5, przeliczona na system dziesiętny wartość wynosi $2 \cdot 16^3 + 1 \cdot 16^2 + 13 \cdot 16^1 + 11 \cdot 16^0 = 8667$. Zgodnie ze standardem przemnożona przez 0.125 obr/min w rezultacie daje prędkość obrotową silnika równą 1083.375 obr/min .

Tabela 5. Fragment pliku danych zarejestrowanych za pomocą interfejsu FMS z pojazdu Scania.


	ID [HEX]	Dane [D1-D8]	Czas
1	18F00029	C0-7D-FF-F3-FF-FF-FF-FF	00.03:33:47.578.9
2	18FEF200	40-00-00-00-FF-FF-FF-FF	00.03:33:47.579.5
3	18F0090B	CF-77-7F-8B-7D-DF-7C-7D	00.03:33:47.580.0
4	18D0FF17	FA-FF-FF-FF-FF-FF-FF-FF	00.03:33:47.580.7
5	0CFE6CEE	FF-FF-FF-FF-00-00-00-00	00.03:33:47.583.9
6	0CF00300	F1-00-1B-FF-FF-FF-FF-FF	00.03:33:47.588.7
7	0CF00400	F0-7D-8B-BD-12-FF-FF-8B	00.03:33:47.589.3
8	18F00503	7D-00-00-7D-20-4E-20-4E	00.03:33:47.590.0
9	18FEF100	F7-00-00-00-03-FF-00-FF	00.03:33:47.590.5

Rejestracja danych przy użyciu interfejsu FMS może prowadzić do uzyskania danych w surowym formacie zaprezentowanym powyżej. Wydajne przeliczenie ich na wartości parametrów pracy pojazdu wymaga skryptów obliczeniowych. Dostępne są również rozwiązania komercyjne oferujące oprogramowania przeliczające dane w czasie rzeczywistym i zapisujące je w żądanym formacie [23]. Dodatkowo oferują najczęściej również śledzenie pojazdu przy użyciu GPS.

1.1.3 Electronic Engine Controller #1: EEC1

0x00F004								PGN Hex
61,444								PGN
20 ms								Rep. Rate
Data Byte 1	Data Byte 2	Data Byte 3	Data Byte 4	Data Byte 5	Data Byte 6	Data Byte 7	Data Byte 8	Byte No
		8 7 6 5 4 3 2 1	8 7 6 5 4 3 2 1	8 7 6 5 4 3 2 1				Bit No
Not used for (Bus) FMS-Standard	Not used for (Bus) FMS-Standard	Actual Engine – Percent Torque 1 % / Bit -125 % offset SPN 513	Engine speed 0.125 rpm / Bit gain 0 rpm offset SPN 190	Engine speed 0.125 rpm / Bit gain 0 rpm offset SPN 190	Not used for (Bus) FMS-Standard	Not used for (Bus) FMS-Standard	Not used for (Bus) FMS-Standard	Name Name values values values SPN

Rys. 5.2. Instrukcja przeliczenia wartości parametrów silnika dla ID F004.



Rys. 5.3. Algorytm obliczenia parametrów pracy pojazdu na przykładzie wiersza nr 7 z Tabeli 5.

5.4. Wykorzystanie FMS w zagadnieniach transportowych


Dostępność informacji na temat parametrów pracy silnika, w szczególności zużycia paliwa oraz łatwość w ich rejestrowaniu stały się motorem rozwoju badań nad zagadnieniami optymalizacji transportu [24,25,26], minimalizacji zużycia paliwa [27,28] i zarządzania flotą pojazdów [29,30]. Ponadto coraz więcej samochodów ciężarowych wyposażonych jest w urządzenia nie tylko rejestrujące dane, ale również przesyłające je bezpośrednio na serwer. Są to komercyjne rozwiązania, które oferują analizę danych wielu pojazdów we flocie klienta. Tak wyposażonych pojazdów w 2012 roku było ponad

3 miliony, a pod koniec 2017 już 6,4 miliona [31]. Obserwując rozwój motoryzacji oraz zagadnień optymalizacji transportu pod kątem zużycia paliwa można spodziewać się, iż w najbliższych latach zdecydowana większość samochodów ciężarowych będzie wykorzystywać dane GPS oraz FMS.

5.5. Moment obrotowy ECU, prędkość obrotowa i strumień masowy paliwa


Opisane w niniejszej pracy metody opierają się na łatwo dostępnych informacjach na temat parametrów pracy silnika, rejestrowanych za pomocą interfejsu FMS. Proponowane metody odwzorowania charakterystyki silnika szerzej opisano w rozdziale 6, przy czym wszystkie z nich polegają na określeniu zależności pomiędzy momentem obrotowym i prędkością kątową, a strumieniem paliwa. Celowe jest zatem określenie relacji pomiędzy parametrami zarejestrowanymi, a parametrami poszukiwanymi.

Prędkość kątowa ω_S oraz masowy strumień paliwa G_e dostępne są z interfejsu FMS, wymagają jedynie przeliczenia na odpowiednie jednostki. Procentowy moment obrotowy wymaga informacji o maksymalnym momencie obrotowym silnika. Ponadto, otrzymana wartość nie oznacza momentu obrotowego na głównym wale odbioru mocy, czy przystawce odbioru mocy. Jest to wartość generowana przez układ wału korbowego, jednak nie uwzględniająca dodatkowych odbiorników w osprzęcie silnika. Na Rys. 5.4 przedstawiony jest model układu napędowego wg GW z wymaganym do niniejszej analizy stopniem szczegółowości. Silnik spalinowy reprezentowany jest w nim przez trzy przetworniki energii. Energia paliwa dostarczona do silnika zamieniana jest na ruch posuwisto zwrotny tłoka w procesach termodynamicznych PT . Wygenerowana siła w cylindrze F_t , i prędkość tłoka V_t zamieniana jest przez układ korbowy UK na ruch obrotowy. Parametry tego ruchu to prędkość kątowa ω_S oraz moment obrotowy M_{ECU} . Rejestracja tych dwóch parametrów dostępna jest przez interfejs FMS. Straty strumienia energii w procesach termodynamicznych oraz podczas ruchu tłoka reprezentowane są odpowiednio przez R_{PT} i R_{UK} . Z wału korbowego silnika WK pobierany jest również strumień energii niezbędny do napędu urządzeń pomocniczych silnika. Element dyssypacyjny R_{WK} reprezentuje zatem w ogólności strumień energii odbieranej przez m.in. alternator, pompę paliwa, układ klimatyzacji. Zatem dopiero moment obrotowy M_S jest momentem wyjściowym z silnika. W literaturze oraz dokumentacji technicznej nie znaleziono szczegółowej informacji na temat tego co dokładnie reprezentuje M_{ECU} , a prezentowane w tym rozdziale wnioski sformułowane są na podstawie badań przeprowadzonych przez autora. Poniżej omówione zostały dwa badania potwierdzające poprawność przyjętego modelu.



Rys. 5.4. Model układu napędowego w formie GW. Silnik spalinowy podzielony na 3 przetworniki strumienia energii (opis w tekście).


Pierwsze badanie przeprowadzono dla samochodu ciężarowego Scania P280. Pojazd pozostawał bez ruchu, na biegu jałowym, z wyłączoną pompą hydrauliczną (zastosowano sprzęgło elektromagnetyczne) oraz wyłączoną klimatyzacją. Prędkość obrotowa silnika została ustawiona na zadaną wartość przez około 2 minuty. Średnie wartości M_{ECU} przedstawione zostały na wykresie poniżej (Rys. 5.5). Podczas pracy silnika bez obciążenia zewnętrznego rejestrowane wartości momentu wynoszą od 118 do 140 Nm dla prędkości obrotowej z zakresu 600 – 1150 obr/min.



Rys. 5.5. Moment obrotowy M_{ECU} podczas pracy silnika bez obciążenia zewnętrznego dla prędkości obrotowej 600 – 1150 obr/min.

Drugie badanie polegało na wymuszeniu wzrostu obciążenia silnika urządzeniem z osprzętu silnika. Moment obrotowy M_{ECU} zależy jest również od dodatkowych odbiorników mocy z silnika, takich jak na przykład alternator. W celu zbadania wpływu mocy ładowania akumulatora na M_{ECU} , przeprowadzono test wykorzystujący odbiornik mocy elektrycznej o mocy 1920 W. Odbiornik w postaci wentylatorów w dwóch chłodnicach oleju hydraulicznego [32] podłączony był bezpośrednio do akumulatora pojazdu (Scania P320). Podczas testu rejestrowano moment M_{ECU} oraz G_e przy stałej prędkości obrotowej, zarówno dla włączonego jak i wyłączonego odbiornika. Test

przeprowadzono dla 7 prędkości obrotowych. Wartości M_{ECU} przedstawione na wykresie (Rys. 5.6) reprezentują wartości średnie z 60 sekund pomiaru.



Rys. 5.6. Moment obrotowy M_{FMS} podczas pracy silnika z włączonym i wyłączonym odbiornikiem energii elektrycznej o mocy 1,92 kW.

Dla włączonego odbiornika wyraźnie widoczna jest większa wartość M_{ECU} w stosunku do wyłączonego dla całego analizowanego zakresu prędkości obrotowej. Tym samym potwierdza to założenia prezentowane w tym rozdziale. Na podstawie prędkości obrotowej i różnicy M_{ECU} obliczono również różnicę w generowanej przez silnik mocy. Jej średnia wartość wynosi 1.1 kW i w 60% pokrywa zapotrzebowanie dodatkowego ładowania akumulatora. Prawdopodobnie w przypadku dłuższych testów, różnica mocy osiągnęłaby wartość 2 kW z uwagi na niewystarczającą ilość energii w akumulatorze.

Zależność między M_{ECU} a M_S została omówiona szerzej w analizie sprawności układu napędowego w rozdziale 11.

6. PRZETWARZANIE SYGNAŁÓW Z INTERFEJSU FMS

W tym rozdziale omówiona została zaproponowana przez autora metoda przetwarzania sygnałów rejestrowanych przy użyciu interfejsu FMS. Metoda obejmuje interpolację sygnału definiującego zużycie paliwa oraz filtrację sygnałów zawierających informację o prędkości obrotowej oraz momencie obrotowym. Teoretyczne uzasadnienie przyjętej metody poparte zostało przykładami wyników badań własnych w postaci wykresów przebiegów rejestrowanych parametrów przed i po zastosowaniu metody.

6.1. Zarys problematyki przetwarzania sygnałów z pojazdu

Podczas prowadzenia pomiarów na stanowiskach badawczych, do mierzenia interesujących parametrów wykorzystywane są urządzenia przetwarzające wielkości fizyczne na sygnały elektryczne. W przypadku prostych czujników są to sygnały analogowe zawierające informację w formie napięcia lub natężenia prądu o stosunkowo niskich wartościach, odpowiednio $0 \div 10 V$ lub $4 \div 20 mA$. Przykładem prostych czujników analogowych są czujniki prędkości obrotowej koła zamachowego, gdzie na sygnał analogowy zamieniane jest zaburzenie pola magnetycznego wywołane obrotem koła. Sygnał wyjściowy z czujnika analogowego w celu rejestracji musi zostać przetworzony na sygnał cyfrowy. Przetwarzanie sygnału ujawnia niedoskonałość sygnału analogowego, który zawiera szum wynikający z różnego rodzaju zakłóceń i zjawisk przypadkowych. Zatem konieczne jest stosowanie filtrów, które wygładzają sygnał i pozwalają dostrzec rzeczywisty przebieg danego parametru. Dla celów przetwarzania sygnałów dostępna jest szeroka gama filtrów o różnym zastosowaniu i złożoności, począwszy od średniej ruchomej, przez filtr Savitzky-Golay, po filtry Chebysheva, Butterwortha czy Kalmana. Dokładny opis metod przetwarzania sygnałów można znaleźć w [33]. Z kolei zastosowanie filtrowania sygnałów na potrzeby badań silników spalinowych opisano między innymi w pracach [34,35,36,37,38,39,40].

Informacje przesyłane po magistrali CAN są sygnałami cyfrowymi. Parametry pracy silnika mierzone przez odpowiednie czujniki przetwarzane są wewnątrz tych urządzeń na zakodowaną informację w postaci komunikatu i nadawane do innych odbiorników w magistrali CAN. Oznacza to, że szum z sygnału analogowego zredukowany jest już na poziomie przetwornika analogowo-cyfrowego w urządzeniu pomiarowym.

Zarejestrowany sygnał pomiarowy zależy w dużej mierze od urządzenia pomiarowego oraz sposobu w jaki zapisuje dane. Z punktu widzenia badacza, najwygodniejszym urządzeniem jest rejestrator z wbudowanym algorytmem filtrującym i wygładzającym oraz rejestrujący wszystkie parametry z jednakowym krokiem czasowym. W takim przypadku przydatną informacją jest znajomość rodzaju filtra jaki

został użyty oraz w jaki sposób dane zostały przeliczone. Dostępne są również urządzenia z modyfikowalnym sposobem rejestracji danych, gdzie czas rejestracji danych lub parametry filtra można dostosować w zależności od potrzeb. Stopień skomplikowania urządzeń pomiarowych jest zwykle proporcjonalny do ich ceny. Przy konieczności redukcji kosztów badań naukowych stosowanym rozwiązaniem jest użycie prostszych urządzeń pomiarowych, a następnie odpowiednia obróbka danych przy użyciu programów komputerowych. Obok dostępnych komercyjnych programów do przetwarzania sygnałów, alternatywą są autorskie programy pisane w powszechnie używanym w nauce środowisku *MATLAB* [41], oraz językach open-source, takich jak np. *R* oraz *Python* [42,43]. W tym rozdziale opisana została procedura zalecana przy przetwarzaniu surowego sygnału zarejestrowanego bezpośrednio z magistrali CAN w postaci ramek z niejednakowym krokiem czasowym. Interpolacja oraz wygładzenie sygnału przeprowadzono w programie *R Studio*, w języka programowania *R*.

Celem obróbki danych pomiarowych jest uzyskanie wartości parametrów w formie tabelarycznej, gdzie w każdym wierszu ze stałym krokiem czasowym znajdują się wartości wszystkich analizowanych parametrów. Szczególnie istotne jest to przy analizie procesów dynamicznych, gdzie przebieg parametrów w czasie tj. wartości w chwilach poprzedzających pomiar ma znaczący wpływ na wartości w momencie pomiaru. Standard J1939 definiuje czas pomiędzy kolejnymi komunikatami przesyłanymi po magistrali CAN przez poszczególne urządzenia. Dla parametrów pracy silnika jest to 20, 50 lub 100 ms. W praktyce jednak sygnały rejestrowane są w niejednakowym odstępie czasowym, przy czym zbliżonym do zakładanego. Przy rekonstrukcji charakterystyki energetycznej silnika pojazdu użytkowego, należy skupić się na procesach zachodzących z częstotliwością nie większą niż 10 Hz [1,44]. Wyższe częstotliwości stają się użyteczne w przypadku analizy zjawisk zachodzących w trakcie jednego cyklu pracy silnika, np. przy pomiarze ciśnienia indykowanego. Do budowy modeli obliczeniowych w dalszej części pracy użyto danych z przyjętym krokiem czasowym równym 100 ms.

6.2. Interpolacja sygnału G_e

Interpolację należy zastosować w przypadku gdy częstotliwość rejestrowanego sygnału jest mniejsza niż częstotliwość potrzebna do analizy zjawiska lub sygnał rejestrowany jest z niejednakowym krokiem czasowym. Według standardu J1939 ramka z informacją o masowym strumieniu paliwa powinna być wysyłana przez urządzenie w odstępie 100 ms. W praktyce rejestracja tego sygnału odbywa się w przedziale 80 – 120 ms, co spowodowane jest wieloma fizycznymi czynnikami, których nie da się

wyeliminować. Aby uzyskać wartości G_e w jednakowym odstępnie czasowym należy zastosować interpolację sygnału, zgodnie ze wzorem:


$$y_{int} = \frac{y_{i+1} - y_i}{t_{i+1} - t_i} \cdot (t_{int} - t_i) + y_i \text{ gdzie } t_{int} \in (t_i, t_{i+1}) \quad (6.1)$$

Gdzie y_{int} to wartość po interpolacji, y_i i y_{i+1} to wartości parametru zarejestrowane przed i po czasie wynikającym z zadanego kroku czasowego. Interpolacja przedstawiona poniżej została przeprowadzona w środowisku R Studio przy użyciu funkcji *approx* z pakietu *stats* [45].


Interpolacja pozwala również na wyeliminowanie przypadkowych braków sygnału. Przerwy te są kłopotliwe w kontekście aplikacji metod numerycznych. Proponowane w dalszej części pracy modele silnika odwzorowujące stany dynamiczne opierają się na algorytmach uwzględniających zarówno historię pracy silnika na krótko przed obserwacją jak i samą obserwację. Algorytmy, które oparte są na n poprzedzających punktach pomiarowych, mają znacząco mniej skomplikowaną budowę od tych opartych na obserwacjach z czasu t poprzedzającego obserwację. Dane wejściowe ze stałym odstępem czasowym pomiędzy obserwacjami gwarantują, że obserwacja numer $n - x$ zarejestrowana była $x \cdot \Delta t$ przed obserwacją n (gdzie Δt to odstęp czasowy). Jeśli algorytm uwzględnia obserwację sprzed 1 sekundy, to dla Δt równego 100 ms wartość x zawsze będzie wynosić 10. Jeśli odstęp czasowy nie jest stały, program dla każdej obserwacji musi obliczyć liczbę x . Komplikuje to kod programu oraz znacznie wydłuża czas obliczeń. Sugerowanym i mniej pracochłonnym rozwiązaniem jest więc odpowiednie przygotowanie danych przed aplikacją algorytmów.

Na Rys. 6.1 przedstawiono czas pomiędzy kolejnymi odczytami ramki FEF2 zawierającej informację o masowym strumieniu paliwa, który oscyluje w zakresie 80 – 120 ms. Widoczne są również dłuższe przerwy (~200 ms). Po procesie interpolacji odstępy są jednakowe, a przerwy zniwelowane. Alternatywnym rozwiązaniem do interpolacji jest zaokrąglenie wartości czasu pomiaru do zadanego kroku. Zmienia to nieznacznie rozkład punktów pomiarowych, jednak główną wadą tej metody jest brak eliminacji przerw w sygnale. Zaokrąglenie można stosować jedynie przy pewności, że przerwy w sygnale nie występują.

Przeprowadzenie interpolacji dla bardzo zbliżonych kroków czasowych nie wpływa na kształt przebiegu parametru. Obrazuje to Rys. 6.2, gdzie fragmenty sygnału G_e przed i po interpolacji nakładają się.



Rys. 6.1. Odstęp czasowy pomiędzy rejestrowanym sygnałem ramki FEF2 oraz krok czasowy po interpolacji.



Rys. 6.2. Sygnał masowego strumienia paliwa G_e przed i po interpolacji.

6.3. Wygładzenie sygnałów n i M

W przypadku gdy sygnał rejestrowany jest z większą częstotliwością niż częstotliwość potrzebna do analizy zjawiska, sygnał należy wygładzić. Dane FMS nie zawierają szumu, więc do wygładzenia można użyć prostego filtra. Poniżej porównane zostały dwa podstawowe filtry stosowane w analizie przebiegów czasowych: średnia ruchoma [46] oraz filtr Savitzky-Golay [47,48].

Filtr oparty na średniej ruchomej wygładza przebieg w każdym z punktów na podstawie średniej w przedziale kilku wartości przed i po obserwacji. Ten przedział wartości nazywany jest oknem i jest parametrem filtra o którym decyduje użytkownik. Okno powinno mieć nieparzystą liczbę elementów, gdzie środkowym jest analizowana obserwacja. Filtr opisany jest wzorem:

$$T_t = \frac{1}{m} \sum_{j=-k}^k y_{t+j} \quad (6.2)$$


Gdzie $m = 2k + 1$; T_t to obliczona wartość parametru; y_{t+j} to wartość parametru w punkcie $t + j$. Wartości y_{t+j} zawarte w oknie zmieniają się dla każdej kolejnej obserwacji, a okno przesuwa się wzdłuż osi czasu – stąd nazwa średniej ruchomej. Im większa szerokość okna, tym bardziej wygładzony przebieg. Przy stosowaniu filtra należy zwrócić uwagę na początek i koniec wygładzanego przebiegu. Filtr wymaga k punktów przed i po obserwacji, zatem dla pierwszych oraz ostatnich k punktów w przebiegu wartości nie są obliczane. Skutkuje to krótszym wygładzonym przebiegiem o $2k$ obserwacji.

Filtr Savitzky-Golay (S-G) polega na dopasowaniu funkcji wielomianowej do fragmentu przebiegu zawartego w oknie przy pomocy metody najmniejszych kwadratów. Wygładzona wartość dla analizowanej obserwacji jest wartością tej funkcji w tym punkcie. Podobnie jak w przypadku średniej ruchomej, to użytkownik definiuje szerokość okna. Dodatkowo decyduje również o stopniu dopasowywanego wielomianu. Filtr S-G w porównaniu ze średnią ruchomą ma mniejsze właściwości redukujące szum, jednak lepiej odwzorowuje pierwotny przebieg. Algorytm jest bardziej skomplikowany oraz wymaga więcej czasu obliczeniowego, jednak biorąc pod uwagę możliwości dzisiejszych komputerów różnica jest pomijalna.


Proponowana procedura obróbki danych z ramki F004 (zawierającej wartości prędkości obrotowej i momentu) z magistrali CAN polega na interpolacji wartości w celu uzyskania jednakowego odstępu czasowego (20 ms) (Rys. 6.3). Podobnie jak w przypadku ramki FEF2 (zawierającej chwilowe zużycie paliwa), użyta do tego zostanie funkcja *approx* z pakietu *stats*. Następnie za pomocą jednej z powyższych metod przebieg zostaje wygładzony w punktach wynikających z przyjętego kroku czasowego 100 ms. Sugerowana szerokość okna wynosi 5, z uwagi na stosunek zadanego kroku czasowego do odstępu $100/20 = 5$, i taka wartość użyta została w dalszej części pracy. Na Rys. 6.4 oraz Rys. 6.6 przedstawione zostały przetworzone sygnały momentu obrotowego oraz prędkości obrotowej wg powyższej procedury. Dla szerokości okna równej 5 obserwacji różnice pomiędzy filtrami są niemal niewidoczne. Dokładniejsze dopasowanie filtra S-G widoczne jest dopiero dla szerszych okien (patrz Rys. 6.5 – szerokość okna 15). W przypadku analizowanych danych FMS największy wpływ wygładzenia na przebieg sygnału obserwowany jest dla momentu obrotowego. Spowodowane jest to rozdzielczością sygnału, która wynosi 1% maksymalnego momentu obrotowego silnika. Dla prędkości

obrotowej rozdzielczość wynosi 0.125 obr/min , co skutkuje łagodniejszymi zmianami parametru.


Do wygładzenia przebiegów średnią ruchomą użyto funkcji *ma* z pakietu *forecast* [49,50], a do wygładzenia filtrem S-G użyto funkcji *sgolayfilt* z pakietu *signal* [51]. Z uwagi na mniejszą wrażliwość na szerokość okna do dalszej analizy użyto filtra Savitzky-Golay (stopnia 3, szer. okna 5).




Rys. 6.3. Odstęp czasowy pomiędzy rejestrowanym sygnałem ramki F004 (zawierającej wartości prędkości obrotowej i momentu) przed i po interpolacji.



Rys. 6.4. Przebieg momentu obrotowego przed i po wygładzeniu filtrem S-G oraz średnią ruchomą. Szerokość okna 5.



Rys. 6.5. Przebieg momentu obrotowego przed i po wygładzeniu filtrem S-G oraz średnią ruchomą. Szerokość okna 15.



Rys. 6.6. Przebieg prędkości obrotowej przed i po wygładzeniu filtrem S-G oraz średnią ruchomą. Szerokość okna 5.

7. METODY ODWZOROWANIA CHARAKTERYSTYKI SILNIKA

W pierwszej części rozdziału omówiona została konwencjonalna metoda odwzorowania charakterystyki silnika przy użyciu aproksymacji funkcją wielomianową, która bazuje na regresji liniowej. Przedstawiono jej teoretyczne podstawy oraz wykorzystanie w literaturze. W dalszej części rozdziału omówiono alternatywne podejście bazujące na uczeniu maszynowym (z ang. Machine Learning - ML). Opisano podstawowe założenia i zasady analizy danych stosowane w ML, takie jak podział na dane treningowe i testowe, *bias-variance tradeoff* czy standaryzacja danych. Następnie określone zostały dwa wskaźniki, których celem jest wzajemne porównanie dokładności stosowanych modeli (*RMSE* oraz R_{adj}^2) oraz dodatkowy wskaźnik oceniający przydatność metody w zastosowaniu inżynierskim $\varepsilon_{\%cykl}$ (procentowy błąd łącznego zużycia paliwa). Alternatywne podejście ML poparte zostało przeglądem literatury, w której uczenie maszynowe znalazło zastosowanie w badaniach silników spalinowych. W dalszej części rozdziału opisano dwie metody ML proponowane do odwzorowania charakterystyki silnika. Pierwsza z nich to metoda K-Najbliższych Sąsiadów (poszukiwanie stanów podobnych), a druga to sztuczne sieci neuronowe (z ang. Artificial Neural Network - ANN). Na końcu rozdziału przedstawiono przykłady obliczeniowe dla każdej z metod, przy czym aproksymacja funkcją wielomianową przeprowadzona została zarówno dla danych ze stanu statycznego jak i dynamicznego. KNN oraz ANN obliczono tylko dla danych ze stanów dynamicznych. Przykłady zawierają wyniki badań własnych.

7.1. Aproksymacja funkcją wielomianową

Do odwzorowania zużycia paliwa powszechnie stosowaną metodą jest wykorzystanie charakterystyki statycznej aproksymowanej funkcją wielomianową. Charakterystyka ogólna silnika (patrz rozdział 1) w rozumieniu tej metody jest funkcją dwóch zmiennych, n oraz M :

$$G_e = f(M_o, \omega), \text{ gdzie } M_o, \omega \in L_s \quad (7.1)$$

Punkty pomiarowe wykorzystywane w tej metodzie pochodzą z badań przeprowadzonych w stanie statycznym silnika, a sama funkcja przyjmuje postać powierzchni wielomianowej n -go stopnia dopasowanej do punktów pomiarowych przy użyciu regresji liniowej.

7.1.1. Regresja liniowa – podejście ogólne

Dowolna zależność między danymi empirycznymi, gdzie X jest zbiorem wartości wejściowych (niezależnych) i y wartością wyjściową (zależną), może być przedstawiona w formie równania:

$$y = f(\mathbf{X}) + \epsilon \quad (7.2)$$

Model regresji liniowej zakłada, że poszukiwana zależność ma charakter liniowy, a funkcja $f(\mathbf{X})$ przyjmuje postać:

$$f(\mathbf{X}) = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p \quad (7.3)$$

W równaniu 7.2 ϵ jest błędem losowym i niezależnym od wartości wejściowych. Oznacza to, że stosując nawet najbardziej zbliżoną do rzeczywistej zależności funkcję matematyczną, model będzie obciążony błędem ϵ , i jest to błąd losowy, nieredukowalny.

Efektom zastosowania regresji liniowej jest uzyskanie funkcji przybliżonej do rzeczywistej zależności:

$$\begin{aligned} \hat{y} &= \widehat{f}(\mathbf{X}) \\ \hat{y} &= \widehat{\beta}_0 + \widehat{\beta}_1 X_1 + \dots + \widehat{\beta}_p X_p \end{aligned} \quad (7.4)$$

Zadaniem regresji jest znalezienie wartości współczynników $\hat{\beta}$, takich aby błąd dopasowania modelu e (z ang. Residual Error) osiągnął minimalną wartość:

$$e = y - \hat{y} \quad (7.5)$$

Przy czym warto zaznaczyć różnicę pomiędzy błędem losowym ϵ a błędem dopasowania modelu e . Z definicji ϵ zawiera się w e :

$$\begin{aligned} e &= \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p + \epsilon - (\widehat{\beta}_0 + \widehat{\beta}_1 X_1 + \dots + \widehat{\beta}_p X_p) \\ e &= (\beta_0 - \widehat{\beta}_0) + (\beta_1 - \widehat{\beta}_1) X_1 + \dots + (\beta_p - \widehat{\beta}_p) X_p + \epsilon \end{aligned} \quad (7.6)$$

Poszukiwanie współczynników $\hat{\beta}$ sprowadza się do znalezienia minimum funkcji sumy kwadratów błędów (RSS – Residual Sum of Squares):

$$RSS = \sum_{i=1}^m e_i^2 \quad (7.7)$$

Gdzie m to liczba obserwacji, a e_i to błąd dopasowania i -tej obserwacji.

Przy stosowaniu regresji linowej do danych zawierających wiele parametrów sugeruje się stosowanie rachunku macierzowego, który jest wygodniejszy w zapisie oraz praktyczniejszy przy stosowaniu metod numerycznych. W zapisie macierzowym powyższe zależności przyjmują postać:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}, \hat{\mathbf{y}} = \mathbf{X}\hat{\boldsymbol{\beta}} \quad (7.8)$$

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \dots \\ y_m \end{bmatrix}_{m \times 1} \quad \mathbf{X} = \begin{bmatrix} 1 & x_{1,1} & x_{1,2} & \dots & x_{1,p} \\ 1 & x_{2,1} & x_{2,2} & \dots & x_{2,p} \\ 1 & x_{3,1} & x_{3,2} & \dots & x_{3,p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{m,1} & x_{m,2} & \dots & x_{m,p} \end{bmatrix}_{m \times (p+1)} \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \dots \\ \beta_p \end{bmatrix}_{(p+1) \times 1} \quad \boldsymbol{\epsilon} = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \dots \\ \epsilon_m \end{bmatrix}_{m \times 1} \quad (7.9)$$

Błąd dopasowanie e :

$$\mathbf{e} = \begin{bmatrix} e_1 \\ e_2 \\ e_3 \\ \dots \\ e_m \end{bmatrix}_{m \times 1} = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \dots \\ y_m \end{bmatrix} - \begin{bmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \hat{y}_3 \\ \dots \\ \hat{y}_m \end{bmatrix} = \mathbf{y} - \hat{\mathbf{y}} \quad (7.10)$$

Suma kwadratów błędów RSS przyjmuje postać :

$$RSS = \mathbf{e}^T \mathbf{e} = (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}) \quad (7.11)$$

Poszukiwany wektor $\hat{\boldsymbol{\beta}}$ dla którego RSS osiąga minimum dany jest wzorem:

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \quad (7.12)$$

7.1.2. Regresja wielomianowa jako szczególny przypadek regresji liniowej

Szczególnym przypadkiem regresji liniowej jest regresja wielomianowa, w której zależność funkcyjna określona jest wielomianem stopnia n :

$$f(\mathbf{X}) = \beta_0 + \beta_1 X + \beta_2 X^2 \dots + \beta_p X^n \quad (7.13)$$

Aby zastosować formalny zapis regresji liniowej do regresji wielomianowej wystarczy odpowiednio zdefiniować wektor zmiennych niezależnych:

$$\mathbf{X} = [1, X, X^2, \dots, X^n] \rightarrow \mathbf{X} = [1, X_1, X_2, \dots, X_p] \quad (7.14)$$

Dla modelu uwzględniającego dwa parametry (X_1 i X_2) opisanego wielomianem drugiego stopnia:

$$f(\mathbf{X}) = \beta_0 + \beta_1 X_1 + \beta_2 X_1^2 + \beta_3 X_1 X_2 + \beta_4 X_2 + \beta_5 X_2^2 \quad (7.15)$$

Wektor \mathbf{X} należy przekształcić

$$\mathbf{X} = [1, X_1, X_1^2, X_1 X_2, X_2, X_2^2] \rightarrow \mathbf{X} = [1, X_1, X_2, X_3, X_4, X_5] \quad (7.16)$$

Dalsza procedura poszukiwania współczynników funkcji $\hat{\mathbf{y}} = \mathbf{X}\hat{\boldsymbol{\beta}}$ jest tożsama z opisaną w poprzednim paragrafie. Przykłady obliczeniowe aproksymacji wykorzystującej regresję wielomianową przy użyciu danych ze stanu statycznego jak i dynamicznego przedstawiono w podrozdziałach 7.5.1 i 7.5.2.

7.1.3. Wykorzystanie aproksymacji funkcją wielomianową – przegląd literatury

Wykorzystanie regresji liniowej w kontekście badań silników spalinowych pojawia się w literaturze już w latach 80-tych, między innymi w pracy [2].

Rozwinięcie metody aproksymacji funkcją wielomianową zaproponował Kropiwnicki w pracy [5,53,54]. Proponowana metoda opierała się na funkcji *spline*, która polega na sklejaniu kilku funkcji wielomianowych we wcześniej zdefiniowanych węzłach, w celu lepszego dopasowania modelu do danych pomiarowych. Metoda pozwala wyeliminować sztuczne ekstrema powstające szczególnie na obrzeżach analizowanego zakresu pola pracy oraz pozwala zredukować stopień użytego wielomianu. Mankamentem tej metody jest konieczność zdefiniowania położenia węzłów sklejaną.

Aproksymowane funkcjami wielomianowymi charakterystyki silnika zostały wykorzystane w pracy [55] do symulowania zużycia paliwa w teście jezdnym, w którym silnik w większości pracował w stanie dynamicznym. Obliczone zużycie paliwa na podstawie charakterystyki uzyskanej w stanie statycznym zostało porównane ze zmierzonym zużyciem. Wartość symulowana była o 6.1% niższa od rzeczywistej.

W pracach [56,57] autorzy przedstawili zagadnienie budowy dynamicznych charakterystyk zużycia paliwa oraz emisji składników spalin na podstawie wyników testów NEDC i FTP-75 przeprowadzonych na hamowni podwoziowej. Charakterystyka dynamiczna potraktowana została jako funkcja prędkości i przyspieszenia aproksymowana funkcją wielomianową trzeciego stopnia. Porównanie opisane w [57] między zużyciem paliwa symulowanym za pomocą charakterystyki dynamicznej i charakterystyki ogólnej, wskazuje na różnice wynoszące nawet 41%.

7.2. Uczenia maszynowe w kontekście badań silników spalinowych

7.2.1. Czym jest Uczenie Maszynowe (Machine Learning)

W analizie danych empirycznych i budowie modelu badanego zjawiska nakład pracy może być skierowany w stronę głębszego zrozumienia mechanizmu działania zjawiska, który ma już pewne podstawy teoretyczne, oraz w stronę budowy modelu, który w większym stopniu skupia się na dokładności w kontekście przewidywania wartości parametrów w przyszłości. Obydwa kierunki bynajmniej nie wykluczają się i większość badań zawiera obydwie podejścia, jednak w różnej proporcji [58,59].

W badaniach o charakterze objaśniającym, zwykle analizowany jest pojedynczy zbiór danych pomiarowych. Zaproponowany model oblicza się za pomocą wykonanych pomiarów, sprawdza zgodność i dokładność modelu względem danych empirycznych, oblicza wskaźniki takie jak R^2 oraz statystyczny poziom istotności. Ocenia się również zgodność modelu z powszechnie przyjętą teorią na temat danego zjawiska i proponuje

modyfikacje lub wskazuje na potrzebę dalszych badań. W wielu przypadkach rozważany jest tylko jeden typ modelu. W ogólności, uwaga badacza skierowana jest na zjawisko w celu lepszego zrozumienia mechanizmów nim rządzących, co w konsekwencji ma prowadzić do określenia dokładnej relacji między analizowanymi parametrami wejściowymi a wyjściowymi. W wielu praktycznych przypadkach prawdziwa natura zjawiska jest wciąż nieznana, a proponowane modele bazują na szczególnych przypadkach danych wejściowych lub wskazują na wpływ pojedynczych parametrów modelu.

W badaniach kładących nacisk na predykcję, wykorzystywane są metody analizujące nie tylko aktualnie dostępne dane, ale też biorące pod uwagę potencjalne dane, które zostaną uzyskane w przyszłości. Znaczenie wpływu pojedynczych parametrów modelu spada na korzyść rosnącej dokładności predykcji. Przy czym należy zaznaczyć, że w modelach o dużej liczbie parametrów wejściowych (np. kilkudziesięciu) dogłębna analiza wpływu poszczególnych z nich jest bardzo trudna. Dane na bazie których został opracowany model określa się jako dane treningowe. Dokładność modelu oceniana jest na podstawie zgodności przewidywania z faktycznymi wartościami parametrów wyjściowych ze zbioru danych testowych.

Obecnie badania opierające się na modelach predykcyjnych zdominowane są przez użycie metod z dziedziny *uczenia maszynowego* (Machine Learning – ML) [60]. Zaletą tych metod jest tworzenie systemów i modeli potrafiących doskonalić się przy pomocy zgromadzonego doświadczenia (czyli danych) i nabywania na tej podstawie nowej wiedzy. Przy czym, pojęcie ‘wiedzy’ rozumiane jest w tym kontekście przez lepszy dobór parametrów wewnątrz algorytmu. Spośród kilku stosowanych definicji ML, warto przytoczyć definicję H. Simsona: "Uczenie się oznacza zmiany w systemie, które mają charakter adaptacyjny w tym sensie, że pozwalają systemowi wykonać za następnym razem takie samo zadanie lub zadania podobne bardziej efektywnie."

Algorytmy ML w sposób automatyczny dobierają optymalne parametry modeli (uczą się) na podstawie dostarczonych danych. Często jest to bardzo atrakcyjna alternatywa do modeli tworzonych w sposób ręczny/analizacyjny. Dzięki temu przez ostatnią dekadę obserwowany jest bardzo dynamiczny rozwój metod ML, a zainteresowanie tymi metodami wykracza poza domenę nauk informatycznych i statystycznych. ML znajduje zastosowanie w niemal każdej dziedzinie życia: wyszukiwarkach internetowych, filtrach wiadomości spam, systemach rekomendacji produktu, prezentowaniu reklamach, wykrywaniu oszustw finansowych, obrotu akcjami na giełdzie, wytwarzaniem leków, przemyśle samochodowym, transporcie i wielu innych. Ostatni raport z McKinsley Global Intitute jasno wskazuje, że ML technologią która będzie głównym motorem kolejnej fali wielkich odkryć i innowacji [61]. ML jest owocem rozwoju

idei sztucznej inteligencji oraz metod jej wdrażania praktycznego, zwłaszcza w postaci oprogramowania w innowacyjnych technologiach i przemyśle. Podstawowym celem zastosowania algorytmu ML jest generalizacja modelu wykraczająca poza dane treningowe. Niezależnie od tego jak duża ilość danych została użyta do wytrenowania modelu, istnieje niska szansa, że identyczne dane znajdują się w zbiorze testowym.

Podstawowym podziałem ML jest podział na uczenie nadzorowane (Supervised Learning - SL) oraz uczenie nienadzorowane (Unsupervised Learning - UL). SL polega na znalezieniu zależności pomiędzy wielkościami wejściowymi a wyjściowymi, przy czym podział definiowany jest przez badacza. Wynikiem SL jest model, który wytrenowany na danych treningowych przewiduje parametry wyjściowe mając do dyspozycji parametry wejściowe z nowych danych. Problemy rozwiązywane przez SL dzielą się na problemy klasyfikacji oraz regresji. Klasyfikacja polega na przypisywaniu obserwacjom klas, a poszukiwana odpowiedź modelu jest zdyskretyzowana, tj. zawiera się w zbiorze $\{0,1\}$, Tak/Nie lub w skończonym zbiorze klas. Problem regresji polega na przewidywaniu odpowiedzi w formie liczbowej, ciągłej. Prognozowanie zużycia paliwa w silniku spalinowym jest w tym kontekście właśnie problemem regresji w uczeniu nadzorowanym i na nim skupia się niniejsza praca. W uczeniu nienadzorowanym (UL) dane nie są podzielone na wejściowe i wyjściowe, a algorytm ma za zadanie znaleźć wcześniej nieznaną zależność między parametrami, przez na przykład grupowanie podobnych przypadków lub wykrywanie anomalii. Podejście UL ma bardziej charakter eksploracyjny niż predykcyjny i pomaga w odkrywaniu struktury analizowanych danych. Metody omawiane w dalszej części pracy skupiają się wyłącznie na uczeniu nadzorowanym. W analizie jasno sprecyzowana jest wielkość wyjściowa modelu (strumień masowy paliwa), a celem budowy modelu jest predykcja zużycia paliwa na podstawie danych zbieranych podczas przyszłych badań pojazdów użytkowych.


Wraz ze wzrostem zainteresowania zagadnieniem uczenia maszynowego, na przestrzeni ostatniej dekady pojawiło się wiele publikacji naukowych prezentujących ML od strony aplikacyjnej. Oprócz badań nad rozwojem algorytmów pod kątem aparatu matematycznego i numerycznego, czyli domeny zarezerwowanej dla ekspertów z dziedziny statystyki i informatyki, prowadzone są badania nad wieloma problemami naukowymi lub inżynierskimi z odległych dziedzin, do których rozwiązania aplikowane jest właśnie ML. Rozwój języków programowania oraz gotowych narzędzi umożliwiających w łatwy sposób aplikacje wybranej metody ML do problemu naukowego, przyczynia się do coraz szerszego wykorzystania algorytmów ML. Komercyjnym oprogramowaniem używanym w wielu jednostkach naukowych jest środowisko *MATLAB* [41]. Jednak popularniejszymi językami w analizie danych są *Python* oraz *R* [43,42],

z uwagi na rozbudowaną społeczność internetową oraz fakt, iż oprogramowanie bazujące na tych językach jest darmowe.

W niniejszej rozprawie część analityczna, tj. przygotowanie i filtracja danych, ocena stanów pracy silnika, obliczenia zużycia paliwa przy weryfikacji proponowanych metod oraz ocena sprawności układu napędowego zostały przeprowadzone w środowisku *R Studio* (język *R*) [42]. W tym celu posiłkowano się pozycjami literaturowymi obejmującymi zarówno podstawy teoretyczne modeli [62,63], jak i sposoby ich aplikacji w formie kodu *R* [64,65,66,67]. Do wizualizacji rezultatów korzystano m.in. z prac [68,69].

7.2.2. Podstawy analizy i problemy w *Uczeniu Maszynowym*

Podstawową praktyką stosowaną podczas budowy modelu ML jest podział danych na dane treningowe, dane walidacyjne i dane testowe (*training set*, *validation set* i *testing set*). Dane treningowe wykorzystywane są oczywiście do treningu modelu, czyli obliczenia funkcji reprezentującej analizowane zjawisko na podstawie dostępnej części danych. Optymalizacja parametrów funkcji odbywa się na drodze minimalizacji przyjętej w danym algorytmie funkcji kosztu/kary. Przykładowo, w regresji liniowej funkcją kosztu jest suma kwadratów błędów (RSS). Dane walidacyjne, wykluczone z procesu treningu, służą do określenia dokładności modelu w przewidywaniu. Na podstawie wartości wejściowych danych walidacyjnych obliczane są przewidywane wartości wyjściowe i porównywane z rzeczywistymi. Dobry model to taki, który przede wszystkim osiąga pożądaną dokładność na danych walidacyjnych. Na podstawie wyniku dla danych walidacyjnych ocenia się model, jego parametry, sens zastosowania danego algorytmu itd. Optymalizacja i dopracowywanie różnych modeli przez badacza odbywa się na danych treningowych i walidacyjnych. Ostateczna weryfikacja końcowego modelu dokonywana jest na danych testowych, wykluczonych z analizy na samym początku [62]. Powyższy przebieg postępowania przedstawiony jest schematycznie na Rys. 7.1. Dane zwykle podzielone są na treningowe, walidacyjne i testowe w proporcji odpowiednio 50-25-25% lub 60-20-20% [59,62].



Rys. 7.1. Przebieg budowy modelu ML [65].

Podział danych w większości przypadków odbywa się poprzez losowy wybór obserwacji spośród całego zbioru. Przyjmując, że dane testowe zostały oddzielone od dalszej analizy w oczekiwaniu na ostateczny model obliczeniowy, jako zbiór dostępnych danych traktowany będzie jako część pozostała (75% lub 80%). Uzyskane w sposób losowy dane treningowe stanowią bazę do budowy modelu, a walidacyjne do jego oceny. Jak to w przypadku procesów losowych bywa, istnieje spora szansa, że ponowny losowy podział pomiędzy tymi dwoma zestawami danych skutkowałby nieco innymi 'optymalnie' dobranymi parametrami modelu oraz inną wartością współczynnika określającego dokładność modelu. Konsekwentnie, wysoka/niska dokładność modelu dla danych walidacyjnych może być wynikiem korzystnego/niekorzystnego podziału. Dane walidacyjne mogą również przypadkowo zawierać wiele obserwacji ze skrajnymi wartościami parametrów co wpłynie na ocenę dokładności modelu. Naturalnym więc jest sprawdzenie wyników dla kilkukrotnego podziału danych. Omawiany problem jest znanym zjawiskiem w ML, a stosowanym narzędziem do jego rozwiązania jest tzw. walidacja krzyżowa (z ang. Cross-validation - CV).




Rys. 7.2. Walidacja krzyżowa 5-krotna. Losowy podział obserwacji na 5 podzbiorów. W każdej iteracji inny podzbiór jest traktowany jako dane walidacyjne. Wynikiem jest wartością uśrednioną ze wszystkich iteracji.

Istotę działania CV zaprezentować można za pomocą k -krotnej walidacji krzyżowej (*k-fold cross-validation*). Polega ona na podziale danych na k części. Za wartość k przyjmowane jest zwykle 5 lub 10 [70], jednak nie jest to wartość z góry narzucona. Podczas pierwszej iteracji część nr 1 traktowana jest jako dane walidacyjne, a suma pozostałych jako dane treningowe. Podczas drugiej iteracji część nr 2 staje się częścią walidacyjną, a suma pozostałych treningową. Po wykonaniu k iteracji wyniki dla każdej z nich są uśredniane. Procedura przedstawiona jest schematycznie na Rys. 7.2. Ostateczna weryfikacja modelu odbywa się poprzez wytrenowanie modelu na wszystkich danych

użytych do optymalizacji jego parametrów (treningowe + walidacyjne) i obliczeniu przewidywanych wartości dla danych testowych.

Zjawiskami, na które należy zwrócić uwagę przy porównywaniu wyników dla danych treningowych i testowych jest tzw. *underfitting* oraz *overfitting*. *Underfitting* występuje gdy przyjęty model jest zbyt prosty aby reprezentować prawdziwą zależność, z kolei *overfitting* oznacza, że model za bardzo dopasował się do danych treningowych. Przykład prezentowany na Rys. 7.3 przedstawia rzeczywisty przebieg funkcji (linia pomarańczowa) oraz punkty pomiarowe, oddalone od funkcji o wartość błędu przypadkowego ϵ . Na wykresie z lewej strony do obserwacji dopasowana została funkcja liniowa, co w oczywisty sposób nie reprezentuje opisywanego zjawiska. Wykres z prawej strony przedstawia wielomian stopnia 15 z dokładnie dopasowanym modelem do obserwacji, jednak powstałe w ten sposób zafalowania spowodują poważne błędy w predykcji na innym zestawie obserwacji. Wykres środkowy reprezentuje najlepszy model, mimo że wartość średniego błędu kwadratowego MSE jest najwyższa. Przykład ten ilustruje jak ważna jest analiza modelu na danych testowych.



Rys. 7.3. *Underfitting* oraz *overfitting* na przykładzie dopasowania funkcją wielomianową stopnia n [71].

Oczekiwany średni błąd kwadratowy modelu e dla obserwacji x_0 ze zbioru danych testowych składa się z trzech elementów: wariancji błędu losowego $Var(\epsilon)$, wariancji funkcji $Var(\hat{y}(x_0))$ oraz kwadratu przesunięcia $Bias(\hat{y}(x_0))^2$:


$$e(x_0)^2 = Var(\epsilon) + Bias(\hat{y}(x_0))^2 + Var(\hat{y}(x_0)) \quad (7.17)$$

Zgodnie w powyższym równaniem, w celu zminimalizowania błędu e wybrany model powinien charakteryzować się jednocześnie niskim *bias* oraz niską wariancją. Wariancja może być rozumiana jako wielkość określająca jak bardzo zmieni się \hat{y} jeśli użyte zostaną inne dane treningowe. W idealnym przypadku wariancja nie powinna zmieniać się znacząco przy stosowaniu różnych danych treningowych. Jeśli jednak

wariancja jest wysoka, oznacza to, że małe zmiany danych treningowych skutkują dużymi zmianami w \hat{y} . Wielomian 15go stopnia z Rys. 7.3 posiada wysoką wariację, ponieważ nieznaczna zmiana rozkład punktów treningowych zmienia znacząco kształt funkcji. Z kolei funkcja stopnia 1 z niską wariacją może jedynie minimalnie zmienić nachylenie [64].

Pojęcie *bias* odnosi się do błędu spowodowanego uproszczeniem, jakie dokonywane jest poprzez próbę dopasowania funkcji \hat{y} do rzeczywistego zjawiska. Przykładowo, opisując funkcją liniową zjawisko, którego przebieg w rzeczywistości przypomina część paraboli, bias osiągnie wysoką wartość niezależnie od tego jak dobrze zostanie wytrenowany model. W ogólności modele bardziej dopasowujące się do danych odznaczają się niższą wartością *bias* [64].

Kluczem do uzyskania dobrego modelu jest kompromis pomiędzy *bias* a wariacją, opisany w literaturze jako *bias-variance tradeoff* [62,64,71]. Wykres z Rys. 7.4 przedstawia błąd e^2 dla danych treningowych i testowych w zależności od stopnia skomplikowania modelu. Błąd treningowy naturalnie będzie dążył do coraz niższych wartości wraz ze wzrostem stopnia skomplikowania modelu oraz wzrostem wariacji. Błąd testowy również maleje, dzięki malejącemu *bias*. Za punktem przegięcia wpływ wariacji staje się większy i obserwowany jest wzrost e^2 . Punkt przegięcia linii błędu testowego wskazuje najlepszy model.



Rys. 7.4. Błąd predykcji na danych treningowych (linia niebieska) i danych walidacyjnych (czerwona) w funkcji stopnia skomplikowania modelu [62].

Istotnym etapem budowania modelu przy użyciu algorytmów ML jest odpowiednie przygotowanie danych. Obok podstawowych czynności, począwszy od usuwania błędnie zarejestrowanych lub rażąco odbiegających (tzw. *outliers*) obserwacji po odpowiednie formatowanie, niezbędnym zabiegiem jest przekształcenie wartości w każdej z cech (cecha - kolumna wartości wejściowych), tak aby miały one ten sam rząd wielkości.

Stosowanych jest kilka przekształceń, z których niewątpliwie należy wyróżnić dwa: normalizacja min-max (*min-max normalization*) oraz standaryzacja (*z-score standardization*).

Normalizacja min-max cechy X w i -tej obserwacji opisana jest wzorem:

$$x_{i,norm} = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (7.18)$$

Zaletą jest łatwa interpretacja uzyskanych wartości, z kolei wadą jest wrażliwość na skrajne wartości w zbiorze danych.

Standaryzacja cechy X w i -tej obserwacji wykorzystuje wartość średnią oraz odchylenie standardowe cechy σ :

$$x_{i,stand} = \frac{x_i - \bar{X}}{\sigma} \quad (7.19)$$

Rezultatem standaryzacji są cechy o średniej wartości równej 0 i odchyleniu standardowym równym 1. Zaletą standaryzacji jest mniejsza wrażliwość na wartości skrajne w zbiorze.

W niektórych modelach, na przykład w liniowej regresji, przekształcenie danych umożliwia porównanie istotności cech pomiędzy sobą. Współczynniki β_n , będące mnożnikami cech, informują o tym jak bardzo odpowiedź modelu zależy od wartości danej cechy. Jeśli jedna z cech ma wartości o kilka rzędów wielkości większe od innych cech, to konsekwentnie jej współczynnik β osiągnie bardzo niską wartość. Uniemożliwia to wzajemne porównanie współczynników. W innych modelach, na przykład w algorytmie k-najbliższych sąsiadów (KNN), przekształcenie jest niezbędne aby algorytm działał poprawnie. W ogólności, transformacja zapewnia stabilność algorytmu podczas numerycznych obliczeń minimum funkcji kosztu.

7.2.3. Uwagi do Uczenia Maszynowego

Zasadą przy doborze algorytmu ML do danego problemu stosowaną w praktyce jest rozpoczęcie analizy od najprostszych algorytmów, np. regresji liniowej czy KNN. Bardziej skomplikowane algorytmy najpewniej będą charakteryzowały się większą dokładnością, jednak są trudniejsze w użyciu. Wymagają dobrania wielu parametrów, zwykle na bazie wiedzy i doświadczenia użytkownika lub też dobrane są na podstawie analizy wyników w wielu iteracjach. Ponadto wewnętrzne zależności w uzyskanym modelu są trudniejsze do interpretacji.

W większości problemów inżynierskich rozwiązywanych za pomocą komputerów, dwoma głównymi ograniczonymi zasobami były czas oraz pamięć operacyjna komputera. W ML trzecim głównym zasobem są dane treningowe. To, który z zasobów był głównym

ograniczeniem zmieniało się na przestrzeni dziesięcioleci. W latach 80tych ograniczeniem była niewielka ilość dostępnych danych. Dziś jest nim czas. Mimo wykładniczego rozwoju możliwości obliczeniowych komputerów, ogromne ilości dostępnych danych pozostają niewykorzystane z prostego powodu – niewystarczającej ilości czasu na ich analizę. Prowadzi to do paradoksu: mimo, że co do zasady większa ilość danych prowadzi do uzyskania dokładniejszych i bardziej skomplikowanych modeli, w praktyce często stosuje się prostsze modele, wymagające znacznie mniej czasu do nauki. Obecnie jednym z głównych kierunków rozwoju ML jest optymalizacja istniejących już algorytmów pod kątem czasu obliczeniowego [72].

Ponadto, ograniczeniem nie technologicznym, ważniejszym od możliwości komputerowej jednostki obliczeniowej, jest możliwość interpretacji i rozumienia człowieka. W publikacjach naukowych, algorytmy są najczęściej porównywane między sobą pod kątem dokładności oraz czasu obliczeń. Często pomijanym czynnikiem jest wysiłek badacza w celu stworzenia skomplikowanego modelu lub też wysiłek jaki został oszczędzony dzięki zastosowanej metodzie. Takie podejście faworyzuje algorytmy prostsze, łatwiejsze w interpretacji. W swojej pracy [73] Domingos podsumowuje, że należy dążyć do modelu prostszego, nie z powodu hipotetycznej relacji z dokładnością, lecz ponieważ prostota jest wartością samą w sobie. Kluczem zatem do uzyskania dobrego modelu jest kompromis między stopniem skomplikowania a dokładnością predykcji na bazie danych testowych. Konieczna jest również znajomość dziedziny, w której algorytm zostaje użyty. W aplikacji ML najlepsze efekty przynosi ścisła współpraca ekspertów ML z ekspertami z dziedziny, gdzie aplikacja ma miejsce [60].

Powszechnie w literaturze silnik pracujący w stanie dynamicznym modelowany jest za pomocą modelu typu „czarna skrzynka” (*black-box*). Wiele procesów zachodzących w silniku jest trudne lub wręcz niemożliwe do opisanego przy obecnym stanie wiedzy [2]. Model typu „czarna skrzynka” pozwala pominąć analizę zjawisk wewnątrz obiektu, skupiając się na parametrach wejściowych i wyjściowych. Zastosowanie takiego modelu przedstawiono m.in. w pracach [74,75,76,77,78,79,80,81,82,83]. Takie podejście pokrywa się z podejściem stosowanym w ML, przez co zastosowanie najnowszych algorytmów staje się atrakcyjną alternatywą w dziedzinie modelowania pracy silnika spalinowego.

7.2.4. Ocena dokładności dopasowania modelu

Do oceny dokładności modelu względem danych pomiarowych stosowane może być co najmniej kilka współczynników opisanych w literaturze. W niniejszej pracy przyjęto dwie wielkości opisujące dokładność dopasowania modelu:

- *RMSE* (Root Mean Squared Error) – pierwiastek ze średniego kwadratu błędu wyrażony w jednostkach wielkości zależnej:

$$RMSE = \sqrt{\frac{RSS}{m}} = \sqrt{\frac{\sum (y - \hat{y})^2}{m}} \quad (7.20)$$

Gdzie m oznacza liczbę obserwacji.

- R_{adj}^2 (adjusted R^2) – dostosowany współczynnik determinacji. R_{adj}^2 zawiera się w przedziale $\langle 0,1 \rangle$. W ogólności przyjmuje się, że wartości z przedziału $\langle 0,8,0,9 \rangle$ oznaczają dopasowanie dobre, a z przedziału $\langle 0,9,1 \rangle$ bardzo dobre. Współczynnik wyrażony jest w formie bezwymiarowej i opisany jest wzorem:

$$R_{adj}^2 = 1 - \frac{RSS(m-1)}{TSS(m-p-1)} \quad (7.21)$$

Gdzie $TSS = \sum_{i=1}^m (y - \bar{y})^2$, p oznacza liczbę niezależnych parametrów wejściowych, a m liczbę obserwacji. Częściej spotykaną wielkością jest współczynnik determinacji R^2 , jednak nie uwzględnia on liczby p . R_{adj}^2 podobnie jak R^2 może być rozumiana jako wielkość wskazująca jaka część zmienności zmiennej y jest wyjaśniona przez wytrenowany model. Matematycznie można dowiedzieć, że uwzględnienie w modelu dodatkowego parametru wejściowego zawsze powoduje zwiększenie R^2 , nawet mimo braku korelacji tego parametru z odpowiedzią modelu \hat{y} . Powoduje to trudności w porównywaniu modeli z różną liczbą parametrów wejściowych. Z uwagi na wykorzystanie i porównanie w niniejszej pracy modeli o różnej liczbie parametrów, użyty został dostosowany współczynnik determinacji R_{adj}^2 , zamiast R^2 .

7.2.5. Ocena modelu w prognozowaniu łącznego zużycia paliwa

Pracę pojazdu użytkowego można opisać jako sumę różnego rodzaju cykli roboczych. W omawianym w tej pracy typie pojazdu użytkowego, śmieciarce, takim cyklem jest na przykład pojedynczy postój z załadunkiem i zagęszczeniem odpadów lub przejazd na wysypisko, rozładunek i przejazd do kolejnego miejsca zbiórki odpadów. Przy tak wyodrębnionych cyklach, wyodrębnić można również ilości paliwa zużywanego w trakcie realizacji każdego z nich. Dodatkowo przy znajomości pracy mechanicznej jaka została wykonana, możliwe jest określenie sprawności cyklu.

Przydatność modelu w aplikacji do oceny sprawności cyklu sprowadza się do dokładności z jaką model przewiduje łączne zużycie paliwa Z_{cykl} w porównaniu z rzeczywistym łącznym zużyciem paliwa $Z_{cykl,rzecz}$:

$$Z_{cykl} = \sum_{i=1}^m (G_{e,i} \cdot \Delta t) \quad (7.22)$$

$$Z_{cykl,rzecz} = \sum_{i=1}^m (G_{e,i,rzecz} \cdot \Delta t) \quad (7.23)$$

Prezentowane w poprzednich akapitach $RMSE$ oraz R_{adj}^2 bazują na bezwzględnych wartościach błędów w poszczególnych obserwacjach. Jednak podczas sumowania przewidywanych wartości zużycia paliwa błędy mogą się zniwelować. Obserwacje z przewidywanym G_e mniejszym niż rzeczywiste zsumowane z obserwacjami z przewidywanym G_e większym niż rzeczywiste (lub odwrotnie) w rezultacie mogą osiągnąć łączne zużycie zbliżone do rzeczywistego $Z_{cykl,rzecz}$. Potrzebny jest zatem nowy wskaźnik określający tę dokładność. W pracy zaproponowany został procentowy błąd łącznego zużycia paliwa $\varepsilon_{\%cykl}$, który określa błąd w cyklu roboczym trwającym czas t_{cykl} .

$$\varepsilon_{\%cykl} = \frac{Z_{cykl} - Z_{cykl,rzecz}}{Z_{cykl,rzecz}} \cdot 100\% \quad (7.24)$$

$$\varepsilon_{\%cykl} = \frac{\sum_{i=1}^m (G_{e,i} \cdot \Delta t) - \sum_{i=1}^m (G_{e,i,rzecz} \cdot \Delta t)}{\sum_{i=1}^m (G_{e,i,rzecz} \cdot \Delta t)} \cdot 100\% \quad (7.25)$$

$$t_{cykl} = m \cdot \Delta t \quad (7.26)$$

Gdzie Δt jest czasem pomiędzy kolejnymi obserwacjami, m jest liczbą obserwacji w rozpatrywanym cyklu, Z_{cykl} jest łącznym przewidywanym zużyciem paliwa, $Z_{cykl,rzecz}$ jest rzeczywistym łącznym zużyciem paliwa.

Wskaźnik $\varepsilon_{\%cykl}$ jest głównym wskaźnikiem oceny modelu podczas badań weryfikacyjnych modeli w rozdziałach 9 i 10.

7.2.6. Aplikacja Uczenia Maszynowego do badań silników spalinowych – przegląd literatury

Sztuczne sieci neuronowe (z ang. Artificial Neural Networks - ANN) aplikowane były w badaniach silników już w latach 90-tych XX wieku, przy czym większość z nich koncentrowała się na silnikach ZI. Jedną z pierwszych prac [84] dotyczyła wykrywania uszkodzeń komponentów silnika. Kolejne prace poruszały problematykę modelowania [85,86,87], przewidywania wyjściowej mocy i emisji spalin [88,89,90], sprawności [91], składu mieszanki [92,93,94,95], wypadania zapłonów [96], spalania stukowego [97] oraz ciśnienia indykowanego [98,99]. Podobne badania przeprowadzano dla silników ZS:

modelowanie emisji spalin w stanie statycznym [100], dynamicznym [89] czy też modelowanie nieliniowej dynamiki turbosprężarki [101,102].

Metody ML cieszą się dużą popularnością w zastosowaniu do predykcji emisji związków toksycznych. Budowane modele najczęściej na podstawie badań na hamowniach silnikowych pozwalają uzyskać wysoką dokładność, przy braku konieczności opisu zjawiska w sposób teoretyczny. Do tego celu szczególnie często wykorzystywane są sztuczne sieci neuronowe [103,104,105,106,107,108,109,110].

Sztuczne sieci neuronowe znajdują również zastosowanie do identyfikacji przebiegu parametrów procesu spalania w silniku ZS. W pracy [111] Longwic przedstawił zastosowanie modelu ANN do identyfikacji modelu wpływu kąta dynamicznego początku tłoczenia paliwa i zawartości eteru etylo-tert-butyłowego w mieszaninie z oleju napędowego na uzyskiwane wartości średniego ciśnienia indykowanego. Z kolei w pracy [112] autorzy zastosowali ANN do identyfikacji modelu wpływu kąta dynamicznego początku tłoczenia paliwa i średniego ciśnienia indykowanego na wartości maksymalnej prędkości narastania ciśnienia wewnątrz komory spalania. W obydwu pracach działanie modelu zostało w ciekawy sposób zobrazowane za pomocą powierzchni odpowiedzi sieci neuronowej.

Modele ANN często porównywane są z innymi metodami ML. W pracach [113,114] wykorzystano metody ML do znalezienia optymalnego stosunku biodiesla w paliwie, w celu redukcji emisji szkodliwych związków oraz zużycia paliwa. Porównano modele Support Vector Machine (SVM) oraz ANN, korzystając z 6-krotnej walidacji krzyżowej oraz wskaźników: średni bezwzględny błąd procentowy (MAPE – mean absolute percentage error) oraz pierwiastek z średniego kwadratowego błędu procentowego (RMSPE – root mean square percentage error). W pracach [115,116,117] na podstawie prędkości obrotowej, obciążenia silnika, strumienia masowego paliwa oraz strumienia powietrza w kolektorze dolotowym, zbudowany został model ANN w celu przewidywania mocy i temperatury gazów wylotowych. Dane uzyskane podczas badań na hamowni silnikowej w stanach statycznych podzielono w stosunku 70-30%, oraz dobrano optymalną liczbę neuronów w warstwie ukrytej. Model ANN charakteryzował się wysokimi wskaźnikami $RMSE$ oraz R^2 , podczas gdy porównany model regresji liniowej uzyskał nieakceptowalnie niską dokładność. Podobne porównanie modeli ANN oraz LR przedstawiono w pracy [118], gdzie na hamowni podwoziowej badano silnik zasilany różnymi rodzajami paliwa. Ponownie ANN odznaczało się kilkukrotnie wyższą dokładnością.

Użycie nowoczesnych metod obliczeniowych ML pozwala również zredukować czas badań eksperymentalnych. W pracy [119] przedstawiono proces kalibracji silnika spalinowego marki Hyundai. Dzięki zastosowaniu modelu bazującego na procesach

gaussowskich (jeden z algorytmów ML) [120] liczba punktów pomiarowych oraz czas badań zostały zredukowane o 76% w porównaniu do tradycyjnej metody. Jednocześnie błąd modelu nie przekraczał przyjętych granicznych 5%.

W pracy [121] przeanalizowano wpływ czynników na przebiegowe zużycie paliwa w 153 pojazdach podczas pokonywania miejskich odcinków, rejestrowanych dzięki magistrali CAN oraz systemowi GPS przez okres miesiąca. Porównane zostały modele Support Vector Machine (SVM), sztuczna sieć neuronowa (ANN), regresja linowa wielu zmiennych oraz zmodyfikowany model SVM. Jako wskaźniki dokładności modelu użyto znormalizowany średni błąd kwadratowy ($NMSE$) oraz R^2 . Badanie miało charakter eksploracyjny, czego wynikiem było wskazanie czynników mających największy wpływ na przebiegowe zużycie paliwa, dzięki przeprowadzeniu analizy wrażliwości. Został wskazany model najlepiej dopasowany do danych (SVM), przy czym dane nie zostały podzielone na treningowe i testowe.

W pracy [122] wykorzystano trzy algorytmy ML w celu predykcji zużycia paliwa autobusu w trakcie przejazdu na długim dystansie, na podstawie dostępnych parametrów jazdy. Modele ANN, Random Forest oraz Gradient Boosting porównane zostały na podstawie dokładności dopasowania do pomierzonych danych. RF uzyskał najwyższą dokładność, przy czym badanie miało charakter eksploracyjny, z ukazaniem istotnych na zużycie paliwa parametrów, a modele trenowano na całości dostępnych danych.

W pracy [123] przedstawiona została analiza zużycia paliwa przez statki kontenerowe, biorąc pod uwagę 21 parametrów, m.in. masę ładunku, wysokość fal, prędkość wiatru czy obciążenie silnika. Zwrócono także uwagę na wzajemną korelację między parametrami, która jest zjawiskiem niepożądanym przy budowie modeli ML. Dane zawierające 884 przebyte kursy 97 statków podzielone zostały w stosunku 80-20%. Na danych treningowych przeprowadzono 10-krotną walidację krzyżową, w celu doboru optymalnych parametrów modeli: LASSO (zmodyfikowana wersja regresji liniowej), ANN, SVR. Model LASSO charakteryzował się najwyższą dokładnością predykcji, przy jednocześnie najkrótszym czasie obliczeń.

W artykule [124] porównano m.in. regresję wielomianową z sieciami neuronowymi w celu stworzenia modelu do predykcji zużycia paliwa w ciężarówkach. Parametrami wejściowymi były prędkość i przyspieszenie pojazdu. Użyte w badaniu dane pochodziły z czterech przeprowadzonych na hamowni podwoziowej testów (Heavy Heavy-Duty Diesel Truck (HHDDT), City Suburban Heavy Vehicle Cycle (CSHVC), New York Composite Cycle (NYCC), and Hydraulic Hybrid Vehicle (HHV)), przy czym zastosowano ciekawe podejście do podziału danych. Modele trenowane były na podstawie jednego z testów, podczas gdy pozostałe traktowane były jako dane testowe. Jako wskaźnik jakości

modelu użyty została procentowa różnica między łącznym zużyciem paliwa zmierzonym a przewidywanym.

W badaniu [125] model ANN reprezentujący silnik w stanie dynamicznym trenowano przez 100 minut według losowo wygenerowanego przebiegu obciążenia i prędkości, z częstotliwością zapisu 10 Hz. Jako dane testowe użyte zostały dane pomiarowe z przeprowadzonych testów homologacyjnych. Model ANN uzyskał wysoką dokładność, a różnica między przewidywaną emisją związków toksycznych a zmierzoną nie przekraczała 5%.

W pracy [126] poruszono problem zużycia paliwa pojazdów ciężarowych wykorzystywanych w kopalniach. Model opierał się na sieci neuronowej, gdzie odpowiedzią na 6 parametrów cyklu roboczego wywrotki, było łączne zużycie paliwa. Przeanalizowano 3250 cykli, dzieląc dane na 3 zestawy w celu walidacji krzyżowej i końcowego testu modelu. Sieć neuronową zoptymalizowano pod kątem parametrów modelu i liczby neuronów w warstwie ukrytej. Błąd modelu na poziomie 10% został uznany za bardzo dobry wynik.

Kolejny przykład wykorzystania ANN znaleźć można w pracy [127], gdzie modelowano sprawność okrętowego układu napędowego. Warto zwrócić uwagę, na uwzględnienie w analizie wpływu liczby obserwacji w danych treningowych na dokładność modelu, określonej przez RMSE.

Problematyka modelowania zużycia paliwa we flotach pojazdów została poruszona w pracy [128]. Na podstawie danych rejestrowanych z magistrali CAN pojazdów ciężarowych przedstawiono porównanie modeli ANN, SVM oraz Random Forest (RF), które na podstawie parametrów pojazdu oraz trasy miały za zadanie przewidzieć zużycie paliwa podczas jazdy autostradowej na odcinku 1600 m. Dodatkowa analiza korelacji pozwoliła zmniejszyć liczbę parametrów wejściowych z 56 do 14. Dane użyte do walidacji krzyżowej stanowiły 96% całego zbioru, pozostałe 4% użyto do weryfikacji modeli.

W pracy [129] opisano budowę modeli opartych na trzech algorytmach: liniowej regresji, ANN oraz SVM, na podstawie danych eksploatacyjnych z trzech samochodów osobowych. Prognozowaną odpowiedzią modelu było chwilowe zużycie paliwa.

7.3. Metoda K-Najbliższych Sąsiadów (KNN)

Modele parametryczne, takie jak liniowa regresja, są relatywnie proste do wytrenowania. Wymagają obliczenia niewielkiej liczby współczynników, które dodatkowo można interpretować pod kątem wpływu na odpowiedź modelu oraz statystycznej istotności. Wadą tych modeli jest jednak konieczność wstępnego założenia

jaką formę ma funkcja \hat{y} reprezentująca obiekt. W przypadku błędnego założenia, skutkiem może być niska dokładność modelu. Alternatywą do modeli parametrycznych są modele nieparametryczne, które mogą być znacznie bardziej elastyczne podczas dopasowywania do danych, kosztem czasu obliczeń i większej trudności w interpretacji modelu.

Jednym z najprostszych algorytmów nieparametrycznych jest algorytm k -najbliższych sąsiadów (z ang. K-Nearest Neighbors – **KNN**). Dla obserwacji x algorytm znajduje k najbliższych obserwacji, które reprezentowane są przez zbiór N_k a następnie oblicza średnią wartość odpowiedzi:

$$\hat{y}(x) = \frac{1}{k} \sum_{x_i \in N_k} y_i(x_i) \quad (7.27)$$

Zbiór N_k definiowany jest dla każdej kolejnej obserwacji x_i poprzez obliczenie odległości d od pozostałych obserwacji x_j . Odległość d opisuje wzór:

$$d(x_i, x_j) = \sqrt{(x_{i,1} - x_{j,1})^2 + (x_{i,2} - x_{j,2})^2 + \dots + (x_{i,p} - x_{j,p})^2} \quad (7.28)$$

Przy stosowaniu algorytmu KNN niezbędnym krokiem w procesie przygotowania danych jest normalizacja lub standaryzacja wartości X . Zgodnie z powyższym wzorem, jeśli dana cecha będzie o rząd wielkości większa od pozostałych, algorytm będzie dopasowywał przyszłe dane pod kątem zminimalizowania odległości właśnie do tej cechy, przy czym wpływ pozostałych cech będzie minimalny. Na taki model duży wpływ mają również jednostki w jakich cecha jest wyrażana. Zatem jeśli przed rozpoczęciem uczenia modelu KNN nie zostanie przeprowadzona standaryzacja (lub normalizacja) danych, model nie będzie traktował przyszłych danych prawidłowo.

Parametrem modelu podlegającym optymalizacji jest k . Im większe wartości k tym większa generalizacja modelu. Mniejsze k skutkuje modelem bardziej dopasowanym do danych treningowych, co może powodować niską dokładność przy weryfikacji modelu na danych testowych.

Model KNN w kontekście analizy pracy silnika spalinowego może być rozumiany jako poszukiwanie stanów podobnych. Dla przyjętego $k = 1$, jest to poszukiwanie najbardziej podobnej pojedynczej obserwacji. Przyjęcie $k > 1$ prowadzi w stronę większej generalizacji modelu, jednak niekoniecznie musi to być tożsame z uzyskaniem wyższej dokładności.


Wadą KNN jest konieczność przechowywania w modelu informacji o wszystkich obserwacjach ze zbioru, na którym trenowany był model. Obliczając pojedynczą przewidywaną wartość \hat{y} konieczne jest przeliczenie d względem każdego punktu

w zbiorze. Im większy zbiór treningowy, tym dłuższy czas obliczeń. Ponadto, czasochłonne obliczenia dokonywane są za każdym razem, gdy prezentowane są nowe dane. W przypadku modeli parametrycznych (regresja liniowa, ANN), modele zawierają zbiór parametrów i współczynników, który tworzy pewnego rodzaju funkcję wykorzystywaną do obliczeń dla nowych danych. Wyznaczenie powyższych odbywa się w procesie treningu, a więc ten czasochłonny proces odbywa się tylko raz. Przewidywane wartości obliczane są dzięki gotowej funkcji, znacznie szybszej od algorytmu KNN. Przykład obliczeniowy metody K-Najbliższych Sąsiadów przy użyciu rzeczywistych danych ze stanu dynamicznego przedstawiony został w podrozdziale 7.5.3.

7.4. Sztuczna sieć neuronowa

Sztuczne sieci neuronowe (ANN) inspirowane są połączeniami nerwowymi, które istnieją w ludzkim mózgu. Neurony odbierają bodźce ze środowiska, i niektóre z nich poprzez aktywację przekazują informację dalej do sąsiadujących neuronów, i tak dalej. Sztuczne sieci neuronowe znajdują wykorzystywane są w szerokim zakresie aplikacji, np. diagnozowaniu chorób, rozpoznawaniu mowy, przetwarzaniu obrazów, przewidywaniu przebiegów czasowych, sterowaniu robotów, i wielu innych.

U podstaw zrozumienia działania ANN leży definicja pojedynczego bloku, który tworzy sieć, czyli neuronu. Neuron może być traktowany jako binarny element decyzyjny (tak/nie; prawda/fałsz; 0-1). Decyzja podejmowana jest na podstawie pewnych wskaźników. Do każdego wskaźnika przypisana jest waga w , która określa jak bardzo istotny jest dany wskaźnik [130,131]. Aby obliczyć wartość wyjściową neuronu $y(x)$, należy obliczyć sumę a iloczynów wartości wejściowych i odpowiadających im wag, a następnie zastosować funkcję aktywacji $\varphi(a)$. Ponieważ wartość wyjściowa powinna przyjmować wartości z zakresu $0 \div 1$, funkcja φ przekształca wartości negatywne w 0, a pozytywne w 1. Schemat podstawowego neuronu przedstawiono na Rys. 7.5. Wartości wejściowe reprezentowane są przez x , przy czym dodatkową wartością wejściową jest *bias* b .




Rys. 7.5. Schemat obliczeniowy prostego neuronu.

Wybór postaci funkcji aktywacji φ zależy od użytkownika, jednak w celu rozwiązywania problemów nieliniowych, φ również powinna być nieliniowa. W przeciwnym razie, procedura obliczeniowa wewnątrz neuronu staje się de facto regresją liniową. Stosowane jest co najmniej kilka typów φ w ANN: sigmoidalna, tangens hiperboliczny, funkcja Gaussa lub zastosowana w niniejszej pracy jednostronnie obcięta funkcja liniowa (ReLU).

Zbiór neuronów uporządkowany w formie szeregu jest nazywany *warstwą*. Wartości x tworzą *warstwę wejściową*, z kolei wartości wyjściowe analogicznie *warstwę wyjściową*. Każda z warstw zawarta pomiędzy powyższymi nazywana jest *warstwą ukrytą*. Każdy z neuronów w warstwie połączony jest ze wszystkimi neuronami w warstwach poprzedniej i następnej, jednak nie jest połączony z neuronami we własnej warstwie (Rys. 7.6). Dobór liczby neuronów w warstwach zależy od użytkownika, i opiera się głównie na jego doświadczeniu w używaniu algorytmu ANN. Zwiększając liczbę ukrytych warstw i/lub liczbę neuronów, w którejkolwiek z nich, sieć staje się coraz bardziej złożona. Powoduje to w jednej strony większe możliwości w dopasowaniu modelu i rozwiązywaniu problemów, z drugiej wzrost poziomu abstrakcji, przez co zrozumienie zależności panujących w modelu staje się niemal niemożliwe.

Mimo, że ANN zawsze przedstawiane są jako warstwy neuronów połączone strzałkami, algorytm obliczeniowy bazuje na rachunku macierzowym. Wartości wejściowe reprezentowane są przez wektor $\mathbf{X} = [x_1, x_2, \dots, x_m]$, z kolei wagi w danej warstwie przez macierz \mathbf{W} , gdzie liczba wierszy odpowiada liczbie neuronów w warstwie, a liczba kolumn liczbie neuronów w warstwie poprzedzającej. Każdy wiersz w \mathbf{W} reprezentuje wagi poszczególnych neuronów. Aby obliczyć wartości wyjściowe z danej warstwy, należy przemnożyć \mathbf{X} i \mathbf{W} oraz dodać wektor *bias* \mathbf{B} . Następnie na każdy element otrzymanego wektora należy zastosować funkcję aktywacji. W rezultacie powstaje wektor, które staje się wektorem wejściowym do kolejnej warstwy. Optymalne wartości \mathbf{W} i \mathbf{B} dobierane są w iteracyjnym procesie treningu sieci na zbiorze danych. W każdej iteracji rzeczywiste wartości porównane zostają z tymi obliczonymi przez sieć. Różnica między nimi obliczana jest za pomocą *funkcji kosztu*. Algorytm analizuje całą sieć i decyduje, jaki poszczególne wartości \mathbf{W} i \mathbf{B} mają wpływ na funkcję kosztu. W celu jej minimalizacji, w kolejnej iteracji te wartości są nieznacznie zmieniane. Ten proces nazywany jest propagacją wsteczną. Kolejne iteracje skutkują coraz mniejszą wartością funkcji kosztu. Gdy obserwowany jest brak poprawy, najprawdopodobniej optymalne \mathbf{W} i \mathbf{B} zostały znalezione.



Rys. 7.6. Struktura sztucznej sieci neuronowej.

Stosowanych jest wiele typów sztucznych sieci neuronowych, o różnym stopniu skomplikowania, funkcjach aktywacji, sposobów obliczania W i B . Omówienie ich wszystkich, podobnie jak przedstawienie dokładnych procedur obliczeniowych wykracza poza zakres niniejszej pracy. W tym podrozdziale opisano podstawy działania jednej z najprostszych ANN, proponowanej do wykorzystania w odwzorowaniu charakterystyki silnika. Przykład obliczeniowy sieci neuronowej z 3 neuronami w jednej warstwie ukrytej przy użyciu rzeczywistych danych ze stanu dynamicznego przedstawiono w podrozdziale 7.5.4.

7.5. Przykłady obliczeniowe rozważanych metod odwzorowania

7.5.1. Aproksymacja funkcją wielomianową – dane ze stanu statycznego

W poniższym przykładzie dysponując danymi empirycznymi z pomiarów pracy silnika w stanie statycznym zastosowana została regresja wielomianowa w celu wyznaczenia powierzchni wielomianowej stopnia trzeciego, aproksymującej charakterystykę silnika $G_e = f(n, M)$. Przedstawione obliczenia zostały przeprowadzone dla 101 obserwacji. Obliczenia w formie macierzowej przedstawiono dla fragmentu danych, losowo wybranych 5 obserwacji.

	X		y
	n [obr/min]	M [Nm]	G_e [g/s]
1	650.0	159.9	2.402
2	850.0	582.9	12.855
3	949.9	588.4	13.280
4	1099.9	287.6	7.310
5	999.9	451.6	10.354

Poszukiwana funkcja wielomianowa stopnia trzeciego wyrażona jest równaniem:

$$G_e(\mathbf{n}, \mathbf{M}) = \beta_0 + \beta_1 n + \beta_2 M + \beta_3 n^2 + \beta_4 nM + \beta_5 M^2 + \beta_6 n^3 + \beta_7 n^2 M + \beta_8 nM^2 + \beta_9 M^3 \quad (7.29)$$

Po przekształceniu odpowiednich wyrazów z równania X otrzymujemy:

$$\mathbf{X} = \begin{bmatrix} 1 & \overbrace{X_1}^{650} & \overbrace{X_2}^{160} & \overbrace{n^2 \rightarrow X_3}^{4.23.E+05} & \overbrace{nM \rightarrow X_4}^{1.04.E+05} & \overbrace{M^2 \rightarrow X_5}^{2.56.E+04} & \overbrace{n^3 \rightarrow X_6}^{2.75.E+08} & \overbrace{n^2 M \rightarrow X_7}^{6.76.E+07} & \overbrace{nM^2 \rightarrow X_8}^{1.66.E+07} & \overbrace{M^3 \rightarrow X_9}^{4.09.E+06} \\ 1 & 850 & 583 & 7.23.E+05 & 4.95.E+05 & 3.40.E+05 & 6.14.E+08 & 4.21.E+08 & 2.89.E+08 & 1.98.E+08 \\ 1 & 950 & 588 & 9.02.E+05 & 5.59.E+05 & 3.46.E+05 & 8.57.E+08 & 5.31.E+08 & 3.29.E+08 & 2.04.E+08 \\ 1 & 1100 & 288 & 1.21.E+06 & 3.16.E+05 & 8.27.E+04 & 1.33.E+09 & 3.48.E+08 & 9.10.E+07 & 2.38.E+07 \\ 1 & 1000 & 452 & 1.00.E+06 & 4.52.E+05 & 2.04.E+05 & 1.00.E+09 & 4.51.E+08 & 2.04.E+08 & 9.21.E+07 \end{bmatrix}$$

$$\mathbf{y} = \begin{bmatrix} 2.402 \\ 12.855 \\ 13.280 \\ 7.310 \\ 10.354 \end{bmatrix}$$

Wynikiem rozwiązania równania 7.12 jest wektor współczynników:

$$\hat{\boldsymbol{\beta}} = \begin{bmatrix} \hat{\beta}_0 = -5.81E+00 \\ \hat{\beta}_1 = 1.44E-02 \\ \hat{\beta}_2 = 1.73E-02 \\ \hat{\beta}_3 = -1.28E-05 \\ \hat{\beta}_4 = -1.09E-06 \\ \hat{\beta}_5 = -1.16E-05 \\ \hat{\beta}_6 = 3.44E-09 \\ \hat{\beta}_7 = 1.23E-08 \\ \hat{\beta}_8 = -2.62E-09 \\ \hat{\beta}_9 = 1.57E-08 \end{bmatrix}$$


Obliczone współczynniki $RMSE$ oraz R_{adj}^2 wskazują na bardzo dobre dopasowanie modelu do danych pomiarowych:

$$RMSE = \sqrt{\frac{0.187}{101}} = 0.0431 \left[\frac{g}{s}\right]$$

$$R_{adj}^2 = 1 - \frac{0.187 \cdot (101 - 1)}{72.353 \cdot (101 - 9 - 1)} = 0.997$$

Otrzymane równanie funkcji przedstawione w formie powierzchni wielomianowej 3-go stopnia wraz z naniesionymi punktami pomiarowymi znajduje się na Rys. 7.7. Powyższe obliczenia numeryczne przeprowadzono w środowisku R używając wbudowanych funkcji z pakietu *stats* [45].

Zastosowanie regresji wielomianowej do modelowania charakterystyki silnika w sposób omówiony w powyższych paragrafach jest poprawne w przypadku badania stanowiskowego w pełnym polu pracy silnika i przy stanie statycznym.



Rys. 7.7. Punkty pomiarowe z badania silnika w stanie statycznym oraz dopasowana powierzchnia wielomianowa stopnia 3 (wyniki badań własnych).

7.5.2. Aproksymacja funkcją wielomianową – dane ze stanu dynamicznego

W poniższym przykładzie wykorzystano fragment danych empirycznych z pomiarów trakcyjnych. Model regresji wielomianowej obliczony został zgodnie z metodologią ML omówioną w poprzednich akapitach. Fragment danych zawierający 402 obserwacje został poddany standaryzacji wg wzoru 7.19. Następnie dane zostały podzielone w stosunku 80-20% na dane treningowe i testowe. Poniżej przedstawiono przykład obliczeń dla i -tej obserwacji w zbiorze danych testowych.

$$n_i = 973 \frac{\text{obr}}{\text{min}}$$

$$M_i = 310,8 \text{ Nm}$$

$$\bar{n} = 814,5 \frac{\text{obr}}{\text{min}}; \quad \sigma_n = 261,1 \frac{\text{obr}}{\text{min}}$$

$$\bar{M} = 290,7 \text{ Nm}; \quad \sigma_M = 216,4 \text{ Nm}$$

$$x_i = [973 \quad 310,8] \rightarrow x_{i,stand} = \left[\frac{973 - 814,5}{261,1} \quad \frac{310,8 - 290,7}{216,4} \right] = [0,607 \quad 0,093]$$

$$y_i = Ge = 1,927 \frac{\text{g}}{\text{s}}$$

Wektor danych wejściowych przekształcony na potrzeby równania 7.29:

$$x_i = [1 \quad 0,607 \quad 0,093 \quad 3,68.E-01 \quad 5,65.E-02 \quad 8,65.E-03 \quad 2,24.E-01 \quad 3,43.E-02 \quad 5,25.E-03 \quad 8,04.E-04]$$

Wynikiem rozwiązywania równania 7.12 jest wektor współczynników:

$$\hat{\beta} = \begin{bmatrix} \hat{\beta}_0 = 1.165 \\ \hat{\beta}_1 = 0.572 \\ \hat{\beta}_2 = 0.685 \\ \hat{\beta}_3 = 0.268 \\ \hat{\beta}_4 = 0.232 \\ \hat{\beta}_5 = -0.070 \\ \hat{\beta}_6 = -0.103 \\ \hat{\beta}_7 = 0.025 \\ \hat{\beta}_8 = 0.013 \\ \hat{\beta}_9 = 0.012 \end{bmatrix}$$

Obliczone wskaźniki dokładności modelu $RMSE$ oraz R_{adj}^2 wynoszą:


$$\begin{aligned} RSS_{training} &= 94.657 & RSS_{test} &= 60.709 \\ RMSE_{training} &= \sqrt{\frac{94.657}{322}} = 0.542 \frac{g}{s} & RMSE_{test} &= \sqrt{\frac{60.709}{80}} = 0.871 \frac{g}{s} \\ R_{adj,training}^2 &= 1 - \frac{94.657 \cdot (322 - 1)}{717.778 \cdot (322 - 9 - 1)} & R_{adj,test}^2 &= 1 - \frac{60.709 \cdot (80 - 1)}{150.780 \cdot (80 - 9 - 1)} \\ &= 0.864 & &= 0.546 \end{aligned}$$

Następnie zastosowano 5-krotną walidację krzyżową na danych wszystkich 402 obserwacjach. Oznacza to, że obliczenia przedstawione powyżej zostały powtórzone pięciokrotnie, za każdym razem traktując inne 20% danych jako dane testowe, a pozostałe 80% jako treningowe (odpowiednio 80 i 322 obserwacji). Średnie wartości $RMSE_{test}$ oraz $R_{adj,test}^2$:


$$\begin{aligned} RMSE_{cv} &= 0.654 \frac{g}{s} \\ R_{adj,cv}^2 &= 0.820 \end{aligned}$$

Porównanie wyników dla pojedynczego testu $RMSE_{test}$ i walidacji krzyżowej $RMSE_{cv}$ jest przykładem na to, jak niekorzystny losowy podział danych może wpłynąć na ocenę modelu.

Obliczona powierzchnia 3go stopnia oraz punkty treningowe i testowe przedstawiono na Rys. 7.8. Przewidywane wartości G_e w zależności od wartości rzeczywistych przedstawione są na Rys. 7.9. Zaletą aproksymacji funkcją wielomianową jest krótki czas obliczeń oraz możliwość wizualizacji uzyskanej funkcji w postaci trójwymiarowej powierzchni.



Rys. 7.8. Dane treningowe (czarne), testowe (czerwone), obserwacja x_i (żółty) oraz funkcja \hat{y} w postaci powierzchni wielomianowej 3go stopnia (wyniki badań własnych).



Rys. 7.9. Wartość G_e zmierzone i przewidywane przez model regresji wielomianowej 3go stopnia dla danych treningowych oraz testowych (wyniki badań własnych).

7.5.3. KNN – poszukiwanie stanów podobnych w danych ze stanu dynamicznego

W poniższym przykładzie wykorzystano fragment danych empirycznych z pomiarów trakcyjnych. Model KNN obliczony został zgodnie z metodologią ML omówioną w poprzednich akapitach. Fragment danych zawierający 402 obserwacje został poddany standaryzacji wg wzoru 7.19. Następnie dane zostały podzielone w stosunku 80-20% na dane treningowe i testowe. Poniżej przedstawiono przykład obliczeń dla i -tej obserwacji w zbiorze danych testowych.

$$n_i = 973 \frac{obr}{min}$$

$$M_i = 310.8 Nm$$

$$\bar{n} = 814,5 \frac{\text{obr}}{\text{min}}; \quad \sigma_n = 261,1 \frac{\text{obr}}{\text{min}}$$

$$\bar{M} = 290,7 \text{ Nm}; \quad \sigma_M = 216,4 \text{ Nm}$$

$$x_i = [973 \quad 310,8] \rightarrow x_{i,stand} = \left[\frac{973 - 814,5}{261,1} \quad \frac{310,8 - 290,7}{216,4} \right] = [0,607 \quad 0,093]$$

$$y_i = Ge = 1,927 \frac{\text{g}}{\text{s}}$$

Dla $x_{i,stand}$ obliczone zostały odległości (wg wzoru 7.28) od wszystkich obserwacji w zbiorze treningowym i uszeregowane od najmniejszej:

<i>Nr obs. j</i>	<i>n</i>	<i>M</i>	$(n_i - n_j)^2$	$(M_i - M_j)^2$	<i>d</i>	<i>G_e</i>
266	-0.010	0.450	0.025	0.011	0.188	1.842
55	-0.098	0.527	0.006	0.036	0.207	2.355
97	0.313	0.515	0.008	0.048	0.238	2.047
173	0.064	0.335	0.074	0.001	0.274	1.641
154	0.158	0.335	0.074	0.004	0.280	1.584
107	0.080	0.324	0.080	0.000	0.284	1.368
160	0.054	0.316	0.085	0.002	0.294	1.467
...

Dla przyjętego $k = 3$ oraz $k = 5$ wartość G_e w punkcie x_i wynosi:

$$\hat{y}_{i,k=3} = \frac{1}{3}(1,842 + 2,355 + 2,047) = 2,081 \frac{\text{g}}{\text{s}}$$

$$\hat{y}_{i,k=5} = \frac{1}{5}(1,842 + 2,355 + 2,047 + 1,641 + 1,584) = 1,894 \frac{\text{g}}{\text{s}}$$

Obserwacja x_i w otoczeniu najbliższych $k = 5$ obserwacji na tle zbioru treningowego przedstawiona została na Rys. 7.10. Przewidywane przez model wartości G_e w zależności od wartości rzeczywistych przedstawione są na Rys. 7.11.

Obliczone wskaźniki dokładności modelu $RMSE$ oraz R_{adj}^2 wynoszą:

Dla $k = 3$

$$RSS_{trening} = 69,291$$

$$RSS_{test} = 64,556$$

$$RMSE_{trening} = \sqrt{\frac{69,291}{322}} = 0,464 \frac{\text{g}}{\text{s}}$$

$$RMSE_{test} = \sqrt{\frac{64,556}{80}} = 0,898 \frac{\text{g}}{\text{s}}$$

$$R_{adj,trening}^2 = 1 - \frac{69,291 \cdot (322 - 1)}{717,778 \cdot (322 - 2 - 1)}$$

$$= 0,903$$

$$R_{adj,test}^2 = 1 - \frac{64,556 \cdot (80 - 1)}{150,780 \cdot (80 - 2 - 1)} = 0,561$$

Dla $k = 5$

$$RSS_{\text{trening}} = 88.962$$

$$RSS_{\text{test}} = 65.038$$

$$RMSE_{\text{trening}} = \sqrt{\frac{88.962}{322}} = 0.526 \frac{g}{s}$$

$$RMSE_{\text{test}} = \sqrt{\frac{65.038}{80}} = 0.902 \frac{g}{s}$$

$$R_{\text{adj,trening}}^2 = 1 - \frac{88.962 \cdot (322 - 1)}{717.778 \cdot (322 - 2 - 1)} = 0.876$$

$$R_{\text{adj,test}}^2 = 1 - \frac{65.038 \cdot (80 - 1)}{150.780 \cdot (80 - 2 - 1)} = 0.569$$

Następnie zastosowano 5-krotną walidację krzyżową na danych wszystkich 402 obserwacjach. Oznacza to, że obliczenia przedstawione powyżej zostały powtórzone pięciokrotnie, za każdym razem traktując inne 20% danych jako dane testowe, a pozostałe 80% jako treningowe (odpowiednio 80 i 322 obserwacji). Średnie wartości $RMSE_{\text{test}}$ oraz $R_{\text{adj,test}}^2$:

$$k = 3$$

$$k = 5$$


$$RMSE_{cv} = 0.699 \frac{g}{s}$$

$$RMSE_{cv} = 0.681 \frac{g}{s}$$


$$R_{\text{adj,cv}}^2 = 0.771$$

$$R_{\text{adj,cv}}^2 = 0.789$$

Niższe wartości $RMSE$ oraz wyższe $R_{\text{adj,test}}^2$ uzyskane podczas walidacji krzyżowej sugerują, że dane testowe uzyskane przy początkowym, jednorazowym podziale charakteryzowały się losowym, niekorzystnym rozkładem obserwacji.



Rys. 7.10. Obserwacja x_i ze zbioru testowego w otoczeniu najbliższych 5 obserwacji zbioru treningowego (wyniki badań własnych).



Rys. 7.11. Wartości G_e zmierzone i przewidywane przez model KNN dla danych treningowych i testowych, dla $k = 3$ oraz $k = 5$ (wyniki badań własnych).

7.5.4. Sztuczna sieć neuronowa – dane ze stanu dynamicznego

W poniższym przykładzie wykorzystano fragment danych empirycznych z pomiarów trakcyjnych. Model ANN obliczony został zgodnie z metodologią ML omówioną w poprzednich akapitach. Fragment danych zawierający 402 obserwacje został poddany standaryzacji wg wzoru 7.19. Następnie dane zostały podzielone w stosunku 80-20% na dane treningowe i testowe. Na potrzeby poniższego przykładu, przyjęto prostą sieć neuronową z 3 neuronami w jednej warstwie ukrytej. Obliczenia zostały przeprowadzone z wykorzystaniem pakietu *neuralnet* [132]. Otrzymana sieć neuronowa przedstawiona jest na Rys. 7.12, wraz z obliczonymi wagami na poszczególnych połączeniach neuronów oraz wartościami *bias*. Na Rys. 7.13 przedstawiono wyniki predykcji modelu dla danych treningowych oraz testowych.

Obliczone wskaźniki dokładności modelu $RMSE$ oraz R_{adj}^2 wynoszą:


$$\begin{aligned}
 RSS_{training} &= 113.104 & RSS_{test} &= 53.075 \\
 RMSE_{training} &= \sqrt{\frac{113.104}{322}} = 0.593 \frac{g}{s} & RMSE_{test} &= \sqrt{\frac{60.011}{80}} = 0.815 \frac{g}{s} \\
 R_{adj,training}^2 &= 1 - \frac{113.104 \cdot (322 - 1)}{717.778 \cdot (322 - 9 - 1)} & R_{adj,test}^2 &= 1 - \frac{53.075 \cdot (80 - 1)}{150.780 \cdot (80 - 9 - 1)} \\
 &= 0.838 & &= 0.603
 \end{aligned}$$

Następnie zastosowano 5-krotną walidację krzyżową na danych wszystkich 402 obserwacjach. Oznacza to, że obliczenia przedstawione powyżej zostały powtórzone pięciokrotnie, za każdym razem traktując inne 20% danych jako dane testowe, a pozostałe


80% jako treningowe (odpowiednio 80 i 322 obserwacji). Średnie wartość $RMSE_{test}$ oraz $R_{adj,test}^2$:

$$RMSE_{cv} = 0.695 \frac{g}{s}$$

$$R_{adj,cv}^2 = 0.717$$



Rys. 7.12. Sztuczna sieć neuronowa o strukturze 2-3-1 z naniesionymi wagami (wyniki badań własnych).



Rys. 7.13. Wartości G_e zmierzone i przewidywane przez model ANN dla danych treningowych i testowych (wyniki badań własnych).

7.6. Podsumowanie

Konwencjonalną metodą odwzorowania charakterystyki silnika jest aproksymacja funkcją wielomianową, która bazuje na punktach pomiarowych ze stanów statycznych. Oznacza to, że podczas badania konieczne jest uzyskiwanie stanów statycznych w wielu

punktach pola pracy silnika. O ile przy testach prowadzonych na hamowniach silnikowych jest to powszechna praktyka, o tyle przy próbach przeprowadzenia badań w trakcie rzeczywistej eksploatacji uzyskiwanie stanów statycznych jest niemal niemożliwe (patrz rozdział 8). Zatem z pomiarów trakcyjnych dysponujemy jedynie (lub w przeważającej większości) punktami pomiarowymi ze stanów dynamicznych. W literaturze nie znaleziono jednak metod w wystarczający sposób opisujących wykorzystanie danych ze stanów dynamicznych do odwzorowania charakterystyki silnika, która umożliwiłaby symulację zużycia paliwa, a w konsekwencji optymalizację układu napędowego pod tym kątem. Stosowanym w literaturze podejściem jest wykorzystanie charakterystyki statycznej (uzyskanej z pomiarów w stanach statycznych) do symulowania zużycia paliwa dla różnych przebiegów, złożonych z punktów w stanach dynamicznych. Uzyskane wyniki porównywane są z zarejestrowanym zużyciem paliwa. Dostarcza to odpowiedzi na pytanie, jakim błędem obarczone jest wykorzystanie charakterystyki statycznej przy zastosowaniu w przebiegach dynamicznych. Problematyka podjęta w niniejszej pracy skupia się na możliwości wykorzystania charakterystyki, która nie wymaga badań silnika w stanie statycznym do jej uzyskania. Nowatorskie podejście wykorzystujące dane z pomiarów trakcyjnych ma w założeniu eliminować konieczność użycia hamowni silnikowej.

Jedną z możliwości jest użycie konwencjonalnej metody, a więc aproksymacji funkcją wielomianową, w celu dopasowania powierzchni n -tego stopnia do punktów pomiarowych ze stanów dynamicznych. W efekcie otrzymujemy charakterystykę o parametrach i wyglądzie charakterystyki statycznej, jednak uzyskanej ze stanów dynamicznych. Innym proponowanym rozwiązaniem jest użycie Sztucznej Sieci Neuronowej lub metody K-Najbliższych Sąsiadów, które dzięki uwzględnieniu historii przebiegu parametrów w czasie mogą skutkować uzyskaniem lepszego modelu. Wyniki symulacji bazujące na konwencjonalnej metodzie traktowane są w dalszej części pracy jako referencyjne, w celu uzasadnienia użycia alternatywnych metod wykorzystujących uczenie maszynowe.

8. STANY DYNAMICZNE SILNIKA W CZASIE RZECZYWISTEJ EKSPLOATACJI

W rozdziale omówione zostało zagadnienie klasyfikacji stanów pracy silnika spalinowego jako statyczne lub dynamiczne. Przedstawione zostało kryterium klasyfikacji zgodne z polską normą PN-ISO 15550:2009 [133] określające maksymalne procentowe odchyłki mierzonych parametrów, oraz kryterium maksymalnej pochodnej zaproponowane w pracy [1]. Następnie zaprezentowana została analiza danych pochodzących z bieżącej eksploatacji pojazdu, mająca na celu ilościową ocenę liczby punktów pomiarowych klasyfikowanych jako statyczne/dynamiczne w zależności od długości przedziału czasu, w jakim dany punkt jest rozpatrywany. Przedstawiona została graficzna interpretacja przyjętych kryteriów oraz wyniki klasyfikacji w postaci histogramów punktów pomiarowych spełniających kryteria w polu pracy silnika.

8.1. Kryterium maksymalnej odchyłki (KMO)

Silnik pracuje w stanie statycznym w chwili t_i , gdy względna odchyłka każdego z parametrów nie przekracza określonej wartości $\theta_{k,dop}$ w przedziale czasu $(t_i - \frac{T}{2}, t_i + \frac{T}{2})$, zgodnie ze wzorem:

$$\max \left(\left| \frac{\left[P_{k,j-\frac{n}{2}}, P_{k,j-\frac{n}{2}+1}, \dots, P_{k,j+\frac{n}{2}-1}, P_{k,j+\frac{n}{2}} \right] - P_{k,j}}{P_{k,j}} \right| \right) \leq \theta_{k,dop} \quad (8.1)$$

Przy czym $P_{k,j} = P_k(t_i)$ oraz

$$P_k(t_i) = \begin{cases} P_1(t_i) \\ P_2(t_i) \\ P_3(t_i) \\ P_4(t_i) \end{cases} = \begin{cases} M(t_i) \\ n(t_i) \\ P(t_i) \\ G_e(t_i) \end{cases} \quad (8.2)$$

Dopuszczalne odchyłki parametrów pracy silnika określone są w normie PN-ISO 15550:2009 [133], oraz przedstawione w Tabeli 6. Norma nie definiuje jednak czasu T , w którym warunki mają być spełnione. Powyższe kryterium przedstawiono również w formie graficznej na Rys. 8.2. Czerwony punkt na przebiegu każdego z parametrów reprezentuje punkt pomiarowy P_k w chwili $t_i = 25$ s. Dla przyjętego przedziału czasowego $T = 2$ s oraz odchyłki przyjętej wg tabeli (± 2 % oraz ± 3 %) linie przerywane określają obszar, w którym powinny znaleźć się wszystkie punkty z przedziału T , aby uznać stan pracy za statyczny. Dla analizowanego punktu P_k tylko wartości n spełniają powyższy warunek, zatem silnik pracuje w stanie dynamicznym. Dla tego samego punktu P_k i dłuższego przedziału $T = 5$ s, żaden z parametrów nie spełnia warunku (Rys. 8.2). Analizując 5 długości przedziału $T = [1$ s, 2 s, 5 s, 10 s, 20 s], na Rys. 8.4 w formie

histogramów przedstawiona została liczba obserwacji spełniających normowe kryterium maksymalnej odchyłki. Nawet dla relatywnie krótkiego przedziału obserwacji 1 s liczba punktów pomiarowych jest niewielka, a ich rozmieszczenie jest nierównomierne.

Tabela 6. Dopuszczalne odchyłki parametrów w badaniach silników w stanach statycznych wg PN-ISO 15550:2009.

Parametr	Dopuszczalna odchyłka	Przykładowe wartości
Moment obrotowy	$\pm 2\%$	$700 \pm 14 \text{ Nm}$
Prędkość obrotowa	$\pm 2\%$	$1000 \pm 20 \text{ obr/min}$
Moc	$\pm 3\%$	$70 \pm 2.1 \text{ kW}$
Zużycie paliwa	$\pm 3\%$	$8 \pm 0.24 \text{ g/s}$
Jednostkowe zużycie paliwa	$\pm 3\%$	$250 \pm 7.5 \text{ g/kWh}$

8.2. Kryterium maksymalnej pochodnej (KMP)

Silnik pracuje w stanie statycznym w chwili t_i , gdy bezwzględna wartość pochodnej każdego z parametrów P_k względem czasu jest mniejsza niż zakładana wielkość ε_k :

$$\left| \frac{\partial P_k(t_i)}{\partial t} \right| < \varepsilon_k \quad (8.3)$$

Jest to podejście zaproponowane przez Chłopka [1]. Wartość bezwzględna umożliwia stosowanie kryterium do dodatnich oraz ujemnych zmian parametrów. Aby analizować pochodną w punkcie pomiarowym P_k konieczne jest uwzględnienie najbliższego otoczenia tego punktu. Formalnie do uzyskania wartości pochodnej wystarczający jest punkt poprzedzający lub następujący, jednak dla odstępu czasowego między obserwacjami $t_i - t_{i-1} = 0,1 \text{ s}$, analiza stanu statycznego w tak krótkim przedziale jest pozbawiona sensu. Celowe jest zatem przyjęcie przedziału czasowego T rzędu kilku sekund, takiego że $t_i \in \langle t_i - \frac{T}{2}, t_i + \frac{T}{2} \rangle$. Następnie do wartości parametru z całego zakresu T dopasowywana jest funkcja liniowa metodą najmniejszych kwadratów. Współczynnik kierunkowy prostej a_k odpowiada za jej nachylenie i jest równoznaczny z wartością pochodnej tej funkcji. Iloczyn a_k i przedziału T określa aproksymowany przyrost parametru ΔP_k :

$$a_k \cdot T = \Delta P_k \quad (8.4)$$

Do analizy stanu statycznego potrzebne jest zdefiniowanie przez badacza przedziału T oraz wielkości dopuszczalnych ε_i dla każdego z parametrów:

$$\varepsilon = [\varepsilon_M, \varepsilon_n, \varepsilon_p, \varepsilon_{Ge}] \quad (8.5)$$

Warunki dla kryterium maksymalnej pochodnej przyjmują postać:

$$\begin{aligned} |a_M| &< \varepsilon_M \\ |a_n| &< \varepsilon_n \\ |a_P| &< \varepsilon_P \\ |a_{Ge}| &< \varepsilon_{Ge} \end{aligned} \quad (8.6)$$

Wartości T oraz ε_i mogą być przyjmowane dowolnie, w zależności od potrzeb badania. Należy zwrócić uwagę na fakt, iż zwiększanie czasu T niesie ze sobą ryzyko zawarcia w przedziale jednocześnie wzrostu i spadku parametru, co w konsekwencji prowadzi do niskiej obliczonej wartości a_k i zakwalifikowania stanu pracy jako statyczny, podczas gdy silnik pracuje w stanie dynamicznym. Kryterium w formie graficznej przedstawiono na Rys. 8.2 oraz Rys. 8.3.

W prezentowanym przykładzie pojazdu, silnik niemal nie pracuje z prędkością wyższą niż 2000 obr/min, a jego moment maksymalny to 1400 Nm. Maksymalne zarejestrowane G_e było równe 13 g/s. Na potrzeby niniejszej analizy, przyjęto połowy z tych wartości oraz sugerując się odchyłkami normowymi (2% oraz 3%) otrzymano ich dopuszczalne przyrosty: $\pm 14 \text{ Nm}$, $\pm 20 \text{ obr/min}$, $\pm 2.1 \text{ kW}$, $\pm 0.24 \text{ g/s}$. Następnie zakładając, że czas w jakim dany przyrost następuje równy 5 sekund, uzyskujemy maksymalne pochodne :

$$\varepsilon = \begin{cases} \varepsilon_M = 2.8 \frac{\text{Nm}}{\text{s}} \\ \varepsilon_n = 4 \frac{\text{obr}}{\text{min} \cdot \text{s}} \\ \varepsilon_P = 0.42 \frac{\text{kW}}{\text{s}} \\ \varepsilon_{Ge} = 0.048 \frac{\text{g}}{\text{s}^2} \end{cases} \quad (8.7)$$

Na Rys. 8.4 przedstawiono liczbę obserwacji spełniających kryterium maksymalnej pochodnej dla rosnącej długości czasu T :

$$T = \{1 \text{ s}, 2 \text{ s}, 5 \text{ s}, 10 \text{ s}, 20 \text{ s}\} \quad (8.8)$$

8.3. Zastosowanie kryteriów do danych z rzeczywistej eksploatacji pojazdu


Rezultatem zastosowania odpowiedniej metody odwzorowania charakterystyki silnika spalinowego jest model silnika. Model konieczny jest do przeprowadzania symulacji systemu energetycznego, w którym dany silnik pracuje. Danymi wejściowymi w symulacji są przebieg prędkości obrotowej silnika oraz przebieg momentu obrotowego. Wynikiem symulacji jest przebieg masowego strumienia paliwa, który jest zbliżony do rzeczywistego przebiegu i zawiera się w założonej dokładności modelu. Jako że model z definicji jest pewnym uproszczeniem rzeczywistego obiektu, akceptowalną dokładność

modelu należy przyjmować zgodnie z możliwościami pomiarowymi oraz z uwzględnieniem stopnia skomplikowania obiektu.

Stany pracy silnika można podzielić na statyczne i dynamiczne, przy czym w warunkach normalnej eksploatacji silnik w zdecydowanej większości czasu pracuje w stanie dynamicznym. Dowodem na to są pomiary trakcyjne przeprowadzone na śmieciarce marki Scania (parametry pojazdu w Tabeli 7). Dane zostały zarejestrowane poprzez interfejs FMS i zawierały informację o prędkości obrotowej n , momencie obrotowym M oraz masowym strumieniu paliwa G_e . Pomiary wykonano w ciągu jednego arbitralnie wybranego dnia pracy pojazdu: czas pomiaru – 8 h, częstotliwość zapisu $f = 10 \text{ Hz}$, 290000 punktów pomiarowych. Na Rys. 8.1 przedstawiono histogram występowania punktów pomiarowych w polu pracy silnika. Koncentracja obserwacji dla $n = 600$ oraz $n = 900 \frac{\text{obr}}{\text{min}}$ jest typowa dla tego typu pojazdu użytkowego (patrz rozdział 2).

Tabela 7. Parametry pojazdu ma którym przeprowadzono pomiary trakcyjne.

Podwozie	Scania P320 6x2
Silnik	ZS o pojemności 9,3 dm ³ , 235 kW (320 KM), 1400 Nm
Typ zabudowy	Śmieciarka tylnozładowcza 19 m ³
Ładowność / DMC	11,5 t / 26 t



Rys. 8.1. Histogram występowania punktów pomiarowych w ciągu 1 dnia pracy śmieciarki (290 tys. obserwacji) (wyniki badań własnych).


Do oceny czy dany punkt pomiarowy w chwili t_i reprezentuje statyczny czy dynamiczny stan pracy, konieczne jest zdefiniowanie najbliższego otoczenia analizowanego punktu. Przyjmując przedział czasowy T , gdzie $t_i \in (t_i - \frac{T}{2}, t_i + \frac{T}{2})$, otoczenie punktu pomiarowego P zawiera $m - 1$ obserwacji, przy czym dla częstotliwości pomiaru f liczba obserwacji $m = T \cdot f$. Do oceny stanu pracy silnika zastosowano dwa kryteria omówione w powyższych akapitach.

8.4. Wyniki poszukiwania punktów pomiarowych pracy silnika w stanie statycznym


Punkty pomiarowe spełniające KMO lub KMP zostały przedstawione na Rys. 8.4. Dla obydwu warunków, dłuższy zakładany czas statyczności naturalnie skutkuje mniejszą liczbą obserwacji. KMO staje się łagodniejsze dla wyższych wartości parametrów z uwagi na procentową wartość odchyłki. Z kolei KMP traktuje parametry jednakowo w całym zakresie, dzięki ustalonej wartości ε . Mankamentem KMP jest możliwość uzyskania niskiej pochodnej w punkcie $P_k(t_i)$, mimo że silnik nie pracuje w stanie statycznym, ponieważ przed obserwacją wartość parametru rośnie (spada), a za obserwacją spada (rośnie). Przykładem takiego zjawiska jest przebieg M na Rys. 8.2, gdzie KMP jest spełnione podczas gdy w przeciągu 2 s obciążenie silnika widocznie się zmienia.

KMO jest kryterium bardziej restrykcyjnym, czego dowodem są histogramy z Rys. 8.4. Porównując liczbę obserwacji spełniających KMO lub KMP z liczbą obserwacji w całym zakresie danych (Rys. 8.1), zasadne jest stwierdzenie, iż silnik spalinowy analizowanego pojazdu w zdecydowanej większości czasu pracuje w stanie dynamicznym.


W dalszej części pracy przedstawione zostały metody odwzorowania charakterystyki silnika spalinowego pojazdu użytkowego, przy użyciu danych zarejestrowanych podczas pomiarów trakcyjnych. Zgodnie z wynikami analizy przedstawionej w tym rozdziale, poprawna metoda wykorzystująca dane eksploatacyjne musi umożliwiać otrzymanie dokładnego modelu bazując na danych ze stanu dynamicznego, ponieważ liczba punktów pomiarowych w stanie statycznym jest niewystarczająca. Każda z metod proponowanych została opisana w sposób teoretyczny oraz zostały przedstawione przykłady użycia metody w badaniach opisanych w literaturze. Następnie metody zostały zweryfikowane używając danych zarejestrowanych podczas pomiarów na stanowisku badawczym opisanym w Załączniku A.




Rys. 8.2. Kryterium maksymalnej odchyłki (z lewej) oraz maksymalnej pochodnej (z prawej) w przyjętym czasie $T = 2$ s w chwili badania $t_i = 25$ s. Dla KMP czerwona linia ciągła oznacza aproksymowaną funkcję liniową, dopuszczalne nachylenie tej linii reprezentuje zielone pole.



Rys. 8.3. Kryterium maksymalnej odchyłki (z lewej) oraz maksymalnej pochodnej (z prawej) w przyjętym czasie $T = 5$ s w chwili badania $t_i = 25$ s. Dla KMP czerwona linia ciągła oznacza aproksymowaną funkcję liniową, dopuszczalne nachylenie tej linii reprezentuje zielone pole.



Rys. 8.4. Ciąg dalszy na następnej stronie.



Rys. 8.4. Liczba punktów pomiarowych spełniających kryterium maksymalnej odchyłki (z lewej) oraz maksymalnej pochodnej (z prawej) dla rosnącej długości czasowego przedziału obserwacji T

9. ANALIZA DOBORU METODY ODWZOROWANIA CHARAKTERYSTYK PRZY WYKORZYSTANIU DANYCH STANOWISKOWYCH

W rozdziale przedstawiono analizę proponowanych metod odwzorowania charakterystyk silnika bazującą na danych uzyskanych podczas testów na specjalnie w tym celu zaprojektowanym stanowisku badawczym.

Na początku rozdziału opisano testy stanowiskowe silnika w stanie statycznym, w tym autorską procedurę pomiarową, prowadzącą do szybkiego wyznaczenia charakterystyki statycznej silnika. Jej poprawność potwierdzona została poprzez porównanie trzech charakterystyk uzyskanych w osobnych badaniach.

W dalszej części rozdziału opisano procedurę testu wymuszającego pracę silnika w stanie dynamicznym, który umożliwił uzyskanie punktów pomiarowych w całym rozpatrywanym zakresie pola pracy. Dane uzyskane w ten sposób wykorzystano do weryfikacji przydatności proponowanych metod w odwzorowaniu charakterystyki silnika. Procedura obliczeniowa obejmująca wielokrotne obliczenia modeli dla różnej liczby punktów pomiarowych umożliwiła statystyczną ocenę dokładności oraz optymalizację parametrów modeli. Dla regresji wielomianowej (RW), przeanalizowano wpływ stopnia wielomianu funkcji i przyjęto jego najlepszą wartość. Z kolei dla modeli K-Najbliższych Sąsiadów (KNN) przeanalizowano wpływ liczby parametrów wejściowych oraz zoptymalizowano parametr k . Sztuczna Sieć Neuronowa (ANN) również zbadana została pod kątem wpływu liczby parametrów wejściowych, a także wpływu liczby neuronów w warstwie ukrytej. Dodatkowymi proponowanymi przez autora parametrami wejściowymi w metodach KNN i ANN są prędkość i moment obrotowy poprzedzające obserwację lub różnice tych parametrów w stosunku do wartości w chwili pomiaru. Każda z metod przeanalizowana została ponadto pod kątem wpływu liczby punktów pomiarowych, a więc wielkości zbioru danych wejściowych na dokładność modeli.

W końcowej części rozdziału modele uzyskane zarówno z testów w stanach statycznych (charakterystyka statyczna - REF) jak i dynamicznych (RW, KNN i ANN) zweryfikowano poprzez symulację zużycia paliwa w cyklu roboczym śmieciarki. Otrzymane wartości porównano z rzeczywistymi, otrzymanymi w badaniach stanowiskowych. Wyniki pozwalają, obok wskazania najlepszej metody, ocenić konieczność uwzględniania stanów dynamicznych w odwzorowaniu charakterystyki silnika oraz ocenić różnicę w dokładności predykcji zużycia paliwa między modelami powstałymi na bazie danych ze stanów statycznych a danych ze stanów dynamicznych. Weryfikacja metod pod kątem przewidywania łącznego zużycia paliwa pozwoliła na ocenę aplikacyjności metod w celach inżynierskich.

9.1. Przebieg badań silnika przy użyciu stanowiska pomiarowego

Zaproponowane w poprzednim rozdziale metody wyznaczenia charakterystyki silnika zostały zweryfikowane na stanowisku testowym. Zasada działania stanowiska opisanym została w Załączniku A. Testowanym pojazdem był pojazd ciężarowy Scania P320 (Rys. 9.1), wyposażony w silnik ZS o pojemności 9.3 dm^3 i mocy maksymalnej 235 kW . Szczegółowe parametry pojazdu oraz silnika spalinowego zawiera Tabela 8.

Przeprowadzone badania zostały podzielone na trzy etapy. Pierwszy z nich polegał na wyznaczeniu charakterystyki ogólnej silnika w stanach statycznych. Drugi etap polegał na obciążeniu silnika zmiennym obciążeniem, w taki sposób aby uzyskać stany dynamiczne silnika w pełnym zakresie jego pracy, możliwym do uzyskania podczas odbioru mocy przez przystawkę. Trzeci etap to badania weryfikacyjne, polegające na zadaniu obciążenia o przebiegu przypominającym rzeczywiste obciążenie silnika pracą zabudowy. Zmierzone w ten sposób zużycie paliwa porównane zostało z symulowanym zużyciem paliwa obliczonym przez modele wytrenowane na danych uzyskanych w dwóch pierwszych etapach.



Rys. 9.1. Scania P320 podczas testów weryfikacyjnych. Na ramie podwozia zamontowane zostało stanowisko testowe (patrz Załącznik A).

Wybrane metody odwzorowania charakterystyki silnika zostały przeanalizowane pod kątem dokładności dopasowania modelu do danych treningowych, testowych oraz walidacyjnych. Zbadano wpływ doboru parametrów danego algorytmu oraz wrażliwość modelu na rozmiar danych treningowych. Ostatnim krokiem weryfikacji metody było obliczenie wskaźnika $\varepsilon_{\%cykl}$ dla najlepszych modeli z danego algorytmu, na podstawie symulowanych cykli roboczych z testu walidacyjnego.

Tabela 8. Specyfikacja techniczna testowanego pojazdu.

Podwozie	Scania P320
DMC	26 t
Pojemność silnika	9.3 dm ³
P_{max}	235 kW / 320 KM
M_{max}	1600 Nm
$M_{PTO,max}$	600 Nm

9.2. Badania w stanie statycznym

9.2.1. Procedura szybkiego wyznaczenia charakterystyki statycznej


W literaturze związanej z badaniami silnika w stanie statycznym nie definiuje się w sposób jednoznaczny czasu, w jakim silnik powinien pracować w stanie statycznym w trakcie testów. Doświadczenie autora płynące z kilkunastu godzin testów stanowiskowych pozwoliło stwierdzić, iż dla przyjętych małych zmian obciążenia i prędkości obrotowej silnika (do 10% maksymalnej wartości) 15 s jest wystarczającym czasem oczekiwania po zmianie nastawy parametrów, aby uznać, że silnik pracuje w stanie statycznym. Układ hydrauliczny oraz układ sterowania stanowiska wymuszały pracę silnika w zadanych punktach pracy (Rys. 9.2), w każdym przez 20 s. Prędkość obrotowa ustawiana była na stałą wartość w przedziale 650 – 1200 $\frac{obr}{min}$, co 50 $\frac{obr}{min}$. Moment obrotowy silnika był odpowiedzią na obciążenie wynikające z pracy układu hydraulicznego i osiągał wartości z zakresu 150 ÷ 650 Nm.:

$$n \in \{650,700,750,800,850,900,950,1000,1050,1100,1150,1200\} \text{ obr/min} \quad (9.1)$$


$$M \in (150, 650) \text{ Nm} \quad (9.2)$$

Zarejestrowane parametry pracy (Rys. 9.3) silnika w trakcie pierwszych 15 s każdego punktu pracy były odrzucane, jako wartości ze stanu dynamicznego. Wartości z pozostałych 5 s były uśredniane i poddawane dalszej analizie (Rys. 9.4).


Badania silnika prowadzone były przy wyłączonych dodatkowych odbiornikach mocy, takich jak np. klimatyzacja, światła, radio. Podczas całego badania silnik pracował w stanie rozgrzanym, tj. temperatura cieczy chłodzącej była wyższa niż 70°C.



Rys. 9.2. Siatka punktów pomiarowych w stanie statycznym w polu pracy silnika.



Rys. 9.3. Punkty pomiarowe z badania stanowiskowego. Silnik w każdym zadany punkt pracy pracował przez 20 s. Na wykresie widoczne również fazy przejścia między punktami pracy.



Rys. 9.4. Uśrednione wartości z punktów pomiarowych z 5 s stanu statycznego.

9.2.2. Weryfikacja procedury w trzech testach stanowiskowych


Badania silnika w stanie stabilnym przeprowadzone zostały trzykrotnie. Każde z nich odbywało się innego dnia, oraz przy innych warunkach atmosferycznych. Warunki przy jakich przeprowadzono testy zestawione są w Tabeli 9.

Tabela 9. Warunki podczas przeprowadzania testów silnika w stanie statycznym.

	Test nr 1	Test nr 2	Test nr 3
Data	6.04.2018	10.04.2018	16.04.2018
Temp. powietrza	11°C	6°C	23°C
Ciśnienie atmosferyczne	1019 hPa	1013 hPa	1012 hPa
Względna wilgotność powietrza	65%	90%	80%

Na podstawie uzyskanych punktów pomiarowych wyznaczona została charakterystyka silnika w postaci powierzchni wielomianowej 3go stopnia wg formuły 7.29 dla każdego z testów. Tok obliczeniowy metody omówiony jest w podrozdziale 7.5.1. Dopasowana powierzchnia do obserwacji z testu nr 1 przedstawiona jest na Rys. 9.5, a zależność pomiędzy zmierzonymi wartościami G_e a przewidywanymi przez model obrazuje Rys. 9.6.

Wszystkie trzy modele obliczone na podstawie danych pomiarowych w poszczególnych testach charakteryzują się wysokim dopasowaniem do obserwacji. Zastosowane do oceny dokładności modelu wskaźniki zawarte są w Tabeli 10Tabela 10. Średnia wartość $RMSE$ z trzech modeli wynosi $0.0481 \frac{g}{s}$, a współczynnik korelacji $R_{adj}^2 = 0.9961$.



Rys. 9.5. Powierzchnia wielomianowa 3go stopnia dopasowana do punktów pomiarowych (kolor czerwony).


Rys. 9.6. Zależność między wartościami G_e zmierzonymi a przewidywanymi.

Tabela 10. Wskaźniki jakości modelu dla trzech testów w stanie statycznym.

	Test 1	Test 2	Test 3	Średnia
Liczba obs.	101	89	91	-
$RMSE \left[\frac{g}{s} \right]$	0.0454	0.0554	0.0434	0.0481
R_{adj}^2	0.9972	0.9946	0.9966	0.9961

9.2.3. Ocena powtarzalności

Przeprowadzone badania silnika w stanie statycznym zostały przeanalizowane pod kątem powtarzalności. W tym celu wszystkie trzy modele wraz z zarejestrowanymi obserwacjami zostały naniesione na układy współrzędnych $G_e(M)$, osobne dla każdej zadanej prędkości obrotowej (Rys. 9.7). Zarówno modele jak i zarejestrowane obserwacje wykazują wysoką zgodność. Dodatkowo dla modelu z testu nr 1 obliczone zostały przedziały predykcji, z prawdopodobieństwem 95%. Przedziały predykcji w tym wypadku określają zakres wartości jaką może przyjąć przewidywane G_e dla dowolnej obserwacji x_i , z założonym prawdopodobieństwem. Oznacza to również, że dla uzyskanego statycznego modelu silnika, 95% obserwacji G_e rejestrowanych podczas innych prób w stanie statycznym powinny zawierać się w przedziale predykcji. Takie zestawienie przedstawiono na Rys. 9.8, gdzie otrzymane przedziały predykcji modelu nr 1 dla każdej z zadanych n porównane zostały z obserwacjami z testów 2 i 3.

Jak wynika z wykresów, wszystkie obserwacje z testów 2 i 3 zawierają się w przedziale predykcji modelu nr 1. Wskazuje to na uzyskanie wiarygodnego modelu silnika w stanie statycznym oraz powtarzalność wyników w przypadku przeprowadzania

innych badań stanowiskowych, zarówno w stanach statycznych jak i dynamicznych. Uzyskana powtarzalność, pomimo nieuwzględniania w modelu wpływu warunków atmosferycznych, czy też dokładnej temperatury silnika, pozwala wnioskować, iż ich wpływ na zużycie paliwa w trakcie testów stanowiskowych jest pomijalny.


Mimo technicznej możliwości, nie połączono danych pomiarowych z trzech testów w jeden zbiór, który użyty zostałby następnie do obliczenia modelu. Taki model odznaczałby się niewątpliwie wierniejszym odwzorowaniem charakterystyki silnika, jednak celem weryfikacji metody jest jej aplikacyjność w kontekście pojedynczego badania silnika, nie zaś jej wykorzystanie mając do dyspozycji wiele wyników różnorodnych testów. Dlatego też, do dalszej analizy i weryfikacji metody wybrany został model nr 1, obliczony na podstawie danych pomiarowych z badania w stanie statycznym nr 1.

Przedstawiona w tym podrozdziale nowa procedura pomiarowa prowadząca do wyznaczenia charakterystyki statycznej silnika odznacza się znacznie mniejszymi nakładami czasowymi i finansowymi w porównaniu do konwencjonalnych procedur. Charakterystyki otrzymane w trzech przeprowadzonych testach potwierdzają powtarzalność tej metody (przedział predykcji 95%).


9.3. Badania w stanie dynamicznym

9.3.1. Opis badania w stanie dynamicznym


Badanie stanu dynamicznego przeprowadzono dla 11 kolejnych prędkości obrotowych z zakresu: $n \in \{700, 750, 800, 850, 900, 950, 1000, 1050, 1100, 1150, 1200\}$. Sterownik silnika ustawiał prędkość obrotową na stałą wartość na czas 100 s, podczas którego silnik poddawany był zmiennemu obciążeniu. Przebieg obciążenia składał się z odcinków o zadanej wartości momentu obrotowego, trwających 3, 4 oraz 5 s. Wielkość obciążenia oraz długość odcinków generowana była w sposób losowy. Fragment przebiegu obciążenia dla prędkości 750 oraz 1050 *obr/min* przedstawiono na Rys. 9.9. Współrzędne punktu pracy silnika rejestrowane były z częstotliwością 10 Hz, a łączny czas pomiaru wynosił 18 min 20 s (1100 s). W rezultacie otrzymano 11000 obserwacji pracy silnika w stanie dynamicznym. Rozkład obserwacji w formie histogramu przedstawiono na Rys. 9.10 oraz jako punkty pomiarowe w trójwymiarowej przestrzeni na Rys. 9.13. Mimo zadanej stałej prędkości obrotowej, w momencie nagłej zmiany M następuje chwilowy spadek lub wzrost n , aż do chwili gdy sterownik silnika dostosuje dawkę paliwa umożliwiającą pracę z zadaną n pod danym obciążeniem. Tłumaczy to występowanie wielu obserwacji o wartościach n pomiędzy zadanymi (czerwone linie na Rys. 9.10).




Rys. 9.7. Porównanie otrzymanych modeli w trzech testach stanowiskowych. Linie reprezentują otrzymane modele regresji na tle punktów pomiarowych. Każdy z wykresów przedstawia zależność $G_e(M)$, dla każdej z zadanych prędkości obrotowych (650-1200).



Rys. 9.8. Porównanie obserwacji z testów 2 i 3 z przedziałem predykcji (95%) modelu z testu nr 1.



Rys. 9.9. Przebieg zadanego obciążenia oraz prędkości obrotowej w czasie podczas badania silnika w stanie dynamicznym.




Rys. 9.10. Rozkład punktów pracy w stanie dynamicznym. Czerwone linie przerywane wskazują na zadaną prędkość obrotową silnika.


9.3.2. *Wzajemne opóźnienie pomiędzy parametrami w stanie dynamicznym*

Przebieg parametrów pracy silnika podczas zmian obciążenia wskazuje na widoczne przesunięcie czasowe Δt pomiędzy zmianami momentu obrotowego a zmianami masowego strumienia paliwa (Rys. 9.11). Nie jest bynajmniej zjawisko charakterystyczne jedynie dla badanego silnika marki Scania. Podobne przesunięcie w sygnałach rejestrowanych poprzez magistralę CAN występuje również w innych testowanych silnikach. Przebiegi parametrów przedstawione na Rys. 9.12 pochodzą z pomiarów trakcyjnych przeprowadzonych na pojazdach MAN TGS 28.420 oraz MAN TGM 26.320. Pojazdy wyposażone były w silniki o pojemności 12.4 dm^3 oraz 10.5 dm^3 ,

i mocy odpowiednio 309 kW oraz 235 kW. Długość Δt nie jest wielkością stałą, zmienia się w zależności od badanego silnika, jego prędkości obrotowej czy wielkości zmian momentu. Zjawisko występowania w sygnałach pomiarowych przesunięcia Δt jest główną przyczyną traktowania pracy silnika jako dynamicznej, a nie statycznej. W pomiarach statycznych Δt nie ma wpływu na mierzoną wartość, ponieważ M i n są stałe przez założony czas. W pomiarach dynamicznych z powodu Δt , dla jednej pary parametrów (n, M), w zbiorze wszystkich obserwacji można odnaleźć różne wartości G_e .



Rys. 9.11. Przebieg parametrów pracy silnika w stanie dynamicznym z zaznaczonym przesunięciem czasowym Δt . Pojazd: Scania P320 z silnikiem 9.3 dm^3 .



Rys. 9.12. Przebieg parametrów pracy silnika w stanie dynamicznym z zaznaczonym przesunięciem czasowym Δt . Pojazdy: MAN TGS 28.420 z silnikiem 12.4 dm^3 (wykres górny) oraz MAN TGM 26.340 z silnikiem 10.5 dm^3 (wykres dolny).

9.4. Procedura obliczeniowa weryfikacji metod na danych z testu dynamicznego

Na podstawie danych pomiarowych z badania silnika w stanie dynamicznym, zweryfikowane zostały metody: regresja wielomianowa, K-Najbliższych Sąsiadów oraz Sztuczna Sieć Neuronowa. Weryfikacja obejmowała zarówno dopasowanie modeli do danych na podstawie wskaźników $RMSE$ i R_{adj}^2 , jak również wrażliwość tych wskaźników na liczbę obserwacji w zbiorze danych treningowych. W tym celu modele trenowane były przy logarytmicznie rosnącej liczbie obserwacji l_{obs} :

$$l_{obs} \in \{100, 139, 195, 273, 383, 535, 750, 1048, 1467, 2052, 2871, 4017, 5620, 7862, 10999\}$$

Każda pojedyncza iteracja obliczeniowa wskaźników dokładności modelu składała się z następujących kroków. Najpierw w sposób losowy pobierana była próbka danych o zadanej wielkości l_{obs} ze zbioru początkowego, liczącego 11000 obserwacji. Następnie próbka dzielona była w proporcji 80/20% na dane treningowe i dane testowe. Dla danych treningowych obliczone zostały wskaźniki: $RMSE_{trening}$ oraz $R_{adj,trening}^2$, a dla danych testowych: $RMSE_{test}$ oraz $R_{adj,test}^2$. Dla każdej wielkości próbki l_{obs} wykonano 30 iteracji. W rezultacie, każdy analizowany model scharakteryzowany był przez 450 wyników.

Analiza każdej z metod uwzględnia również dobór optymalnych parametrów modelu oraz zdefiniowanie parametrów wejściowych.

9.5. Model z wykorzystaniem regresji wielomianowej dla danych z testu w stanie dynamicznym


9.5.1. Opis zastosowanych modeli

Podobnie jak w przypadku danych pomiarowych ze stanu statycznego, do odwzorowania charakterystyki silnika w stanie dynamicznym została użyta regresja wielomianowa. Poszukiwana funkcja $\hat{y} = G_e(n, M)$ zakłada dopasowanie powierzchni do punktów pomiarowych z Rys. 9.13, przy czym dane za każdym razem dzielone były na treningowe i testowe. Takie podejście w pewnym sensie zakłada, że punkty w stanie dynamicznym nie różnią się od punktów w stanie statycznym, ponieważ aproksymacja funkcją wielomianową zwykle stosowana jest jedynie do stanów statycznych.

Obok wskaźników dopasowania, przeanalizowany został wpływ stopnia wielomianu na dokładność modelu. Analizowane stopnie wielomianu to $n_{wiel} \in \{2, 3, 4, 5\}$. Poszukiwana funkcja zakłada zależność między prędkością obrotową i momentem obrotowym a masowym strumieniem paliwa: $\hat{y} = G_e(n, M)$, przy czym wektor parametrów wejściowych powiększa się o dodatkowe parametry wynikające ze stopnia użytego wielomianu. Przykładowo dla stopnia 3go liczba parametrów zwiększa się z dwóch do dziewięciu:

$$G_e(\mathbf{n}, \mathbf{M}) = \beta_0 + \beta_1 n + \beta_2 M + \beta_3 n^2 + \beta_4 nM + \beta_5 M^2 + \beta_6 n^3 + \beta_7 n^2 M + \beta_8 nM^2 + \beta_9 M^3 \quad (9.3)$$

Dla wielomianu stopnia 2go, 4go oraz 5go liczba parametrów wejściowych wynosi odpowiednio 5, 14 oraz 20. Tak różna liczba parametrów uzasadnia użycie R_{adj}^2 zamiast R^2 przy wzajemnym porównaniu modeli.



Rys. 9.13. Zużycie paliwa zarejestrowane w teście silnika w stanie dynamicznym.

9.5.2. Omówienie wyników

Procedura obliczeniowa z 9.4 przeprowadzona została dla każdego n_{wiel} . Wyniki obliczeń wskaźników dopasowania w zależności od wielkości próbek przedstawiono w Tabeli 11 oraz na Rys. 9.14. Wykresy zawierają wartości średnie z 30 wyników dla danej l_{obs} oraz zacieniowane obszary reprezentujące odchylenie standardowe.

Mimo rosnącego rozmiaru próbki, $RMSE_{test}$ nie spada poniżej 0.300 g/s, a $R_{adj, test}^2$ nie osiąga wartości powyżej 0.820. Spowodowane jest to faktem, iż powierzchnia wielomianowa, niezależnie od przyjętego kształtu, nie może dobrze dostosować się do rozmieszczonych w przestrzeni punktów pomiarowych ze stanu dynamicznego (Rys. 9.15). Sugeruje to, iż założona funkcja \hat{y} jest niewłaściwa (wysoki *bias*) lub błąd przypadkowy osiąga zbyt duże wartości aby otrzymać dokładniejszy model (Rys. 9.16).

Dla wielomianów 4go i 5go stopnia wyraźnie widoczne jest nadmierne dopasowanie do danych treningowych (*overfitting*). Świadczy o tym wysoka różnica między wskaźnikami treningowymi a testowymi. Istotną informacją jest to jak model zachowuje się przy niewielkiej liczbie obserwacji w zbiorze treningowym. Im wyższy stopień wielomianu, tym bardziej funkcja staje się dopasowana dla niewielkiej liczby punktów treningowych. Skutkuje to błędną predykcją dla danych testowych,


co szczególnie widoczne jest dla stopnia 5go i $l_{obs} \leq 273$, gdzie $RMSE_{trening} = 0.250$ a $RMSE_{test} = 0.390$. Dla $l_{obs} > 1000$ wyniki nie ulegają poprawie, i niezależnie od stopnia wielomianu przyjmują zbliżone wartości, zarówno dla danych treningowych jak i testowych.

Tabela 11. Wskaźniki dokładności regresji wielomianowej 3go stopnia na podstawie pomiarów w stanie dynamicznym. Wartości średnie z 30 iteracji, w nawiasach odchylenie standardowe (sd).


l_{obs}	$RMSE_{trening}(sd)$	$RMSE_{test}(sd)$	$R^2_{adj,trening}(sd)$	$R^2_{adj,test}(sd)$
100	0.28 (0.029)	0.32 (0.086)	0.82 (0.04)	0.62 (0.189)
139	0.28 (0.029)	0.30 (0.051)	0.82 (0.032)	0.73 (0.088)
195	0.28 (0.018)	0.32 (0.047)	0.81 (0.047)	0.7 (0.088)
273	0.29 (0.019)	0.31 (0.033)	0.82 (0.026)	0.77 (0.05)
383	0.3 (0.014)	0.32 (0.026)	0.82 (0.019)	0.78 (0.045)
535	0.29 (0.011)	0.30 (0.026)	0.81 (0.02)	0.81 (0.035)
750	0.3 (0.013)	0.30 (0.026)	0.82 (0.011)	0.81 (0.038)
1048	0.3 (0.008)	0.3 (0.018)	0.81 (0.014)	0.81 (0.024)
1467	0.3 (0.007)	0.3 (0.016)	0.82 (0.01)	0.81 (0.025)
2052	0.3 (0.007)	0.3 (0.015)	0.82 (0.009)	0.81 (0.017)
2871	0.3 (0.004)	0.3 (0.012)	0.82 (0.007)	0.82 (0.014)
4017	0.3 (0.004)	0.3 (0.01)	0.82 (0.005)	0.82 (0.014)
5620	0.3 (0.003)	0.3 (0.007)	0.82 (0.004)	0.81 (0.008)
7862	0.3 (0.003)	0.3 (0.006)	0.82 (0.003)	0.82 (0.007)
10999	0.3 (0.002)	0.3 (0.005)	0.82 (0.002)	0.81 (0.006)

Stosowanie wielomianu stopnia większego niż 3 nie wiąże się ze zwiększeniem dokładności modelu. Niesie ze sobą natomiast ryzyko, iż wyższy stopień spowoduje znacznie większe błędy przy predykcji, szczególnie jeśli model trenowany był na niewielkiej liczbie obserwacji. Wielomiany stopnia 2 i 3 wykazują mniejszą wrażliwość na rozmiar próbki.


Do dalszej weryfikacji wybrany został model opierający się na regresji wielomianowej 3go stopnia (**RW**).



Rys. 9.14. . Regresja wielomianowa: zależność $RMSE_{trening}$ i $RMSE_{test}$ oraz $R^2_{adj,trening}$ i $R^2_{adj,test}$ od l_{obs} oraz stopnia wielomianu. Linia ciągła – wartości średnie dla 30 wyników, zacieniowany obszar – odchylenie standardowe. Linia przerywana dla $l_{obs} = 750$.



Rys. 9.15. Powierzchnia wielomianowa (3go stopnia) dla 600 punktów treningowych (punkty niebieskie) i 150 testowych (punkty czerwone), $l_{obs} = 750$.



Rys. 9.16. Zależność między wartościami G_e zmierzonymi a przewidywanymi przez regresję wielomianową 3go stopnia (RW) wytrenowaną na 600 obserwacjach, testowaną na 150 obs.

9.6. Model KNN dla danych z testu w stanie dynamicznym

9.6.1. Dobór optymalnych parametrów wejściowych i parametru k

W analizie KNN założono dwie możliwe funkcje \hat{y} reprezentujące prace silnika w stanie dynamicznym:

$$\hat{y}_1 = G_e(n, M) \quad (9.3)$$

$$\hat{y}_2 = G_e(n, M, n_{500}, n_{1000}, n_{1500}, M_{500}, M_{1000}, M_{1500}) \quad (9.4)$$

Indeks dolny parametrów oznacza czas w milisekundach, jak dawno dana wartość została zarejestrowana w stosunku do obserwacji. Przykładowo, n_{500} oznacza wartość prędkości obrotowej 500 ms przed obserwacją, a M_{1000} moment obrotowy 1000 ms przed obserwacją.

Funkcja \hat{y}_1 stanowi bezpośrednio porównanie z opisaną w poprzednich akapitach regresją wielomianową. Funkcja \hat{y}_2 uwzględnia wartości poprzedzające obserwację, co przy analizie stanu dynamicznego powinno prowadzić do zwiększenia dokładności modelu. Oznacza to, że \hat{y}_2 nie analizuje pojedynczego stanu pracy silnika, a proces stanu pracy.

Obliczenia zostały przeprowadzone zgodnie z procedurą opisaną w podrozdziale 9.4 dla 4 modeli: **KNN 1**, **KNN 2**, **KNN 3** i **KNN 4** (Tabela 12). Parametrem podlegającym optymalizacji w algorytmie KNN jest k , określający liczbę poszukiwanych najbliższych punktów w wielowymiarowej przestrzeni parametrów wejściowych X . W dwóch modelach, po jednym dla każdej funkcji \hat{y} , ustawiona została wartość $k = 1$, jako reprezentacja najprostszego poszukiwania pojedynczego najbliższego punktu. W dwóch kolejnych k dobierane było w każdej iteracji na podstawie wskaźnika $RMSE_{test}$. Wyniki $RMSE$ oraz R_{adj}^2 w zależności od l_{obs} przedstawiono na Rys. 9.17.


Tabela 12. Wyniki dla modeli KNN. W nawiasach podane odchylenie standardowe.

Model	k	\hat{y}	Średnie wyniki dla $l_{obs} = 750$				
			k_{opt}	$RMSE_{tren}$	$RMSE_{test}$	$R_{adj,tren}^2$	$R_{adj,test}^2$
KNN 1	1	\hat{y}_1	1	0	0.377 (0.036)	1	0.724 (0.050)
KNN 2	{1,3,5, ...,23,25}	\hat{y}_1	5	0.293 (0.011)	0.308 (0.024)	0.827(0.015)	0.801 (0.034)
KNN 3	1	\hat{y}_2	1	0	0.138 (0.013)	1	0.960 (0.009)
KNN 4	{1,3,5, ...,23,25}	\hat{y}_2	11	0.096 (0.009)	0.110 (0.015)	0.981 (0.004)	0.974 (0.008)

9.6.2. Omówienie wyników

Biorąc pod uwagę wyniki treningowe, najwyższą dokładność, $RMSE_{tren} = 0$ i $R_{adj,tren}^2 = 1$, osiągają modele KNN 1 i KNN 3. Spowodowane jest to dopasowaniem do $k = 1$ najbliższej obserwacji. Oznacza to, że przewidywana wartość jest równa wartości treningowej, a zatem błąd dopasowania jest zerowy. Jest to zjawisko charakterystyczne dla algorytmu KNN. Dopiero dla $k > 1$ w wyniku uśredniania wartości przewidywanej pojawiają się błędy dopasowania w danych treningowych. Nie oznacza to jednak, że te modele osiągną wysoką dokładność dla nowych, wcześniej nieznanymi danych. Dlatego też tak ważna jest weryfikacja przy użyciu danych testowych, z której wynika, że modele KNN

2 i KNN 4 ze zoptymalizowanym parametrem k osiągają wyższą dokładność od swoich odpowiedników z $k = 1$ dla danych testowych.




Rys. 9.17. KNN: zależność $RMSE_{trening}$ i $RMSE_{test}$ oraz $R_{adj,trening}^2$ i $R_{adj,test}^2$ od l_{obs} oraz rodzaju modelu. Linia ciągła – wartości średnie dla 30 wyników, zacieniowany obszar – zakres \pm odchylenia standardowego. Linia przerywana dla $l_{obs} = 750$.

Biorąc pod uwagę wyniki testowe, KNN 1 osiąga najwyższy $RMSE_{test}$, który jest niemal niezależny od rozmiaru próbki. KNN 2, dobierając optymalną wartość k , pozwala uzyskać mniejszy błąd niż w przypadku RW, jednak dopiero dla $l_{obs} > 1000$. Dokładność modeli KNN 3 i KNN 4 rośnie wraz z l_{obs} , przy czym dzięki optymalizacji parametru k ,

KNN 4 osiąga $RMSE_{test}$ poniżej 0.20 już dla najmniejszej próbki, aż do 0.06 dla całego dostępnego zbioru danych.

W modelach KNN 3 i KNN 4 wskaźniki dopasowania zarówno treningowe jak i testowe poprawiają się wraz ze zwiększeniem l_{obs} . Oznacza to, iż modele nie mają skłonności do nadmiernego dopasowania (*overfittingu*). Zgodnie z oczekiwaniami dotyczącymi algorytmu k-Najbliższych Sąsiadów, modele wykazują wysoką wrażliwość na rozmiar danych treningowych.

Podobnie jak w przypadku RW, szczegółowe wyniki przedstawione zostały dla modelu bazującego na $l_{obs} = 750$ (Tabela 12). Model KNN 2 nawiązujący do RW uzyskał podobną, niską dokładność, przejawiając ten sam problem, tj. trudność w dopasowaniu modelu opartego na dwóch parametrach wejściowych do zarejestrowanych G_e w stanie dynamicznym (Rys. 9.18). Modele uwzględniające historię obserwacji charakteryzują się znacznie wyższą dokładnością, osiągając $RMSE_{test} = 0.138$ i 0.110 g/s, $R_{adj, test}^2 = 0.960$ i 0.974 , dla odpowiednio KNN 3 i KNN 4.




Rys. 9.18. Model KNN 2 w formie powierzchni dopasowanej do 600 punktów treningowych – punkty niebieskie. Punkty czerwone - 150 obserwacji testowych. $k_{opt} = 19$.

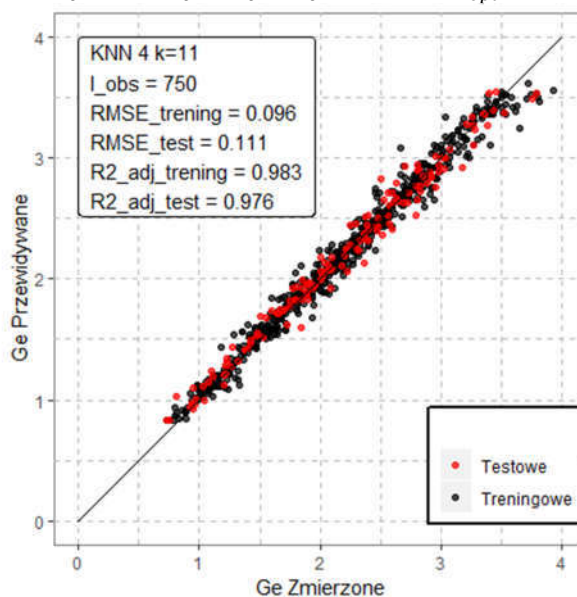
Przy poszukiwaniu k_{opt} , model dopasowywany jest dla każdego k z rozpatrywanego zakresu. k_{opt} to takie, dla którego model uzyskuje najniższe $RMSE_{test}$. Wyniki dla 30 iteracji z rosnącym parametrem k przedstawiono w formie wykresów skrzynkowych na Rys. 9.19. Rosnące k powoduje coraz większe generalizowanie modelu, przez co $RMSE_{trening}$ rośnie. Jest to zjawisko typowe dla KNN. Analiza $RMSE_{test}$ pozwala wskazać $k_{opt} = 11$, przy czym wartości z zakresu $5 \div 15$ osiągają zbliżone wyniki. Bazując na jednej iteracji prawdopodobny jest wybór innego k_{opt} , biorąc pod uwagę niewielkie

różnice w wykresach skrzynkowych, przy czym nie spowoduje to drastycznego spadku dokładności modelu.

Do dalszej weryfikacji wybrany został model KNN 4, z $k=11$. Wysoka dokładność wybranego modelu przedstawiona jest w formie zależności G_e przewidywanego od zmierzonego na Rys. 9.20.



Rys. 9.19. Wykres skrzynkowy RMSE wykorzystany do doboru k_{opt} dla modelu KNN 4 i $l_{obs} = 750$.



Rys. 9.20. Zależność między wartościami G_e zmierzonymi a przewidywanymi przez model KNN 4 wytrenowany na 600, testowany na 150 obserwacjach.

9.7. ANN dla danych z testu w stanie dynamicznym

9.7.1. Dobór optymalnych parametrów wejściowych i liczby neuronów w warstwie ukrytej

Metoda sztucznych sieci neuronowych przeanalizowana została pod kątem wrażliwości na rozmiar danych treningowych, doboru parametrów wejściowych, oraz liczby neuronów w warstwie ukrytej. Przyjęty w analizie typ sieci to sieć jednokierunkowa

z propagacją wsteczną. Funkcję aktywacji (przejścia) stanowiła jednostronnie obcięta funkcja liniowa (*rectified linear unit* – ReLU). Maksymalna liczba iteracji w procesie optymalizacji wag wynosiła 100 (*epoch* = 100).

W analizie ANN założono 5 szukanych funkcji \hat{y} . Pierwsza z nich, \hat{y}_1 , nawiązuje do modelu referencyjnego (RW) uwzględniając jedynie n i M w chwili obserwacji. Funkcje \hat{y}_2 oraz \hat{y}_4 zawierają informację o wartościach poprzedzających obserwację, odpowiednio po jednej wartości n i M sprzed 1000 ms oraz po 3 wartości n i M sprzed 500, 1000 i 1500 ms. Funkcje \hat{y}_3 oraz \hat{y}_5 uwzględniają zmiany parametrów w czasie przed obserwacją. Zmianę symbolizuje Δ , a indeks dolny określa czas w milisekundach. Przykładowo, $\Delta n_{1000} = n - n_{1000}$ lub $\Delta M_{1500} = M - M_{1500}$. W literaturze znaleźć można modele uwzględniające w modelu wartości n i M lub ich zmiany w pewnym oknie czasowym poprzedzającym obserwację, jednak brakuje uargumentowanych sugestii co do długości tego okna. Dlatego też przy weryfikacji metody przeanalizowane zostały 2 modele z dodatkowymi wartościami sprzed 1 s, oraz 2 modele z dodatkowymi wartościami sprzed 0.5, 1 oraz 1.5 s. Analizowane modele zestawione zostały w Tabeli 13.

Podczas weryfikacji ANN przeanalizowano również wpływ stopnia złożoności modelu na dokładność. Pod pojęciem złożoności w algorytmie ANN rozumiana jest struktura sieci, a konkretnie liczba ukrytych warstw oraz liczba neuronów w tych warstwach. Założono jedną warstwę ukrytą, z uwagi na fakt iż opisywane zjawisko jest relatywnie proste w porównaniu do problemów, dla których zastosowanie więcej niż jednej ukrytej warstwy przynosi korzyści rekompensujące koszt obliczeniowy. Każdy z modeli trenowany był dla liczby neuronów w warstwie ukrytej z zakresu $N_{neu,ukr} \in \{5,10,15,20,30\}$. Liczba neuronów w warstwie wejściowej $N_{neu,wej}$ zależna była od liczby parametrów wejściowych (od 2 do 8). Odpowiedzią modelu była wartość G_e , zatem w warstwie wyjściowej znajdował się 1 neuron.

Procedura trenowania modeli przeprowadzona była zgodnie z procedurą trenowania opisaną w podrozdziale 1.4, analogicznie jak dla RW i KNN. Dla wybranej $l_{obs} = 750$ wskaźniki dopasowania modelu zestawiono w Tabeli 14. Ponadto w celu analizy wpływu struktury sieci na dopasowanie modelu, wskaźniki zestawiono w formie wykresów skrzynkowych na Rys. 9.21. Wpływ wielkości próbki na wskaźniki dopasowania przedstawiono na Rys. 9.22. Z uwagi na wyraźnie gorsze dopasowanie modelu, wyniki w formie graficznej dla ANN 1 przedstawiono na osobnym wykresie w odpowiedniej skali (Rys. 9.23).

Tabela 13. Podsumowanie analizowanych modeli ANN i ich struktury.

Model	Poszukiwana funkcja \hat{y}	$N_{neu,wej}$	$N_{neu,ukr}$	$N_{neu,wyj}$
ANN 1	$\hat{y}_1 = G_e(n, M)$	2	5	1
ANN 2	$\hat{y}_2 = G_e(n, M, n_{1000}, M_{1000})$	4	10	
ANN 3	$\hat{y}_3 = G_e(n, M, \Delta n_{1000}, \Delta M_{1000})$	4	15	
ANN 4	$\hat{y}_4 = G_e(n, M, n_{500}, n_{1000}, n_{1500}, M_{500}, M_{1000}, M_{1500})$	8	20	
ANN 5	$\hat{y}_5 = G_e(n, M, \Delta n_{500}, \Delta n_{1000}, \Delta n_{1500}, \Delta M_{500}, \Delta M_{1000}, \Delta M_{1500})$	8	30	

Tabela 14. Wyniki dla modeli ANN.


Model	Średnie wyniki dla $l_{obs} = 750, N_{neu,ukr} = 5$			
	$RMSE_{tren}$	$RMSE_{test}$	$R_{adj,tren}^2$	$R_{adj,test}^2$
ANN 1	0.304 (0.012)	0.305 (0.021)	0.806 (0.019)	0.801 (0.033)
ANN 2	0.104 (0.013)	0.109 (0.021)	0.977 (0.006)	0.974 (0.011)
ANN 3	0.099 (0.012)	0.111 (0.026)	0.979 (0.006)	0.972 (0.018)
ANN 4	0.079 (0.012)	0.089 (0.021)	0.987 (0.004)	0.982 (0.01)
ANN 5	0.078 (0.015)	0.091 (0.024)	0.987 (0.006)	0.981 (0.012)

9.7.2. Omówienie wyników

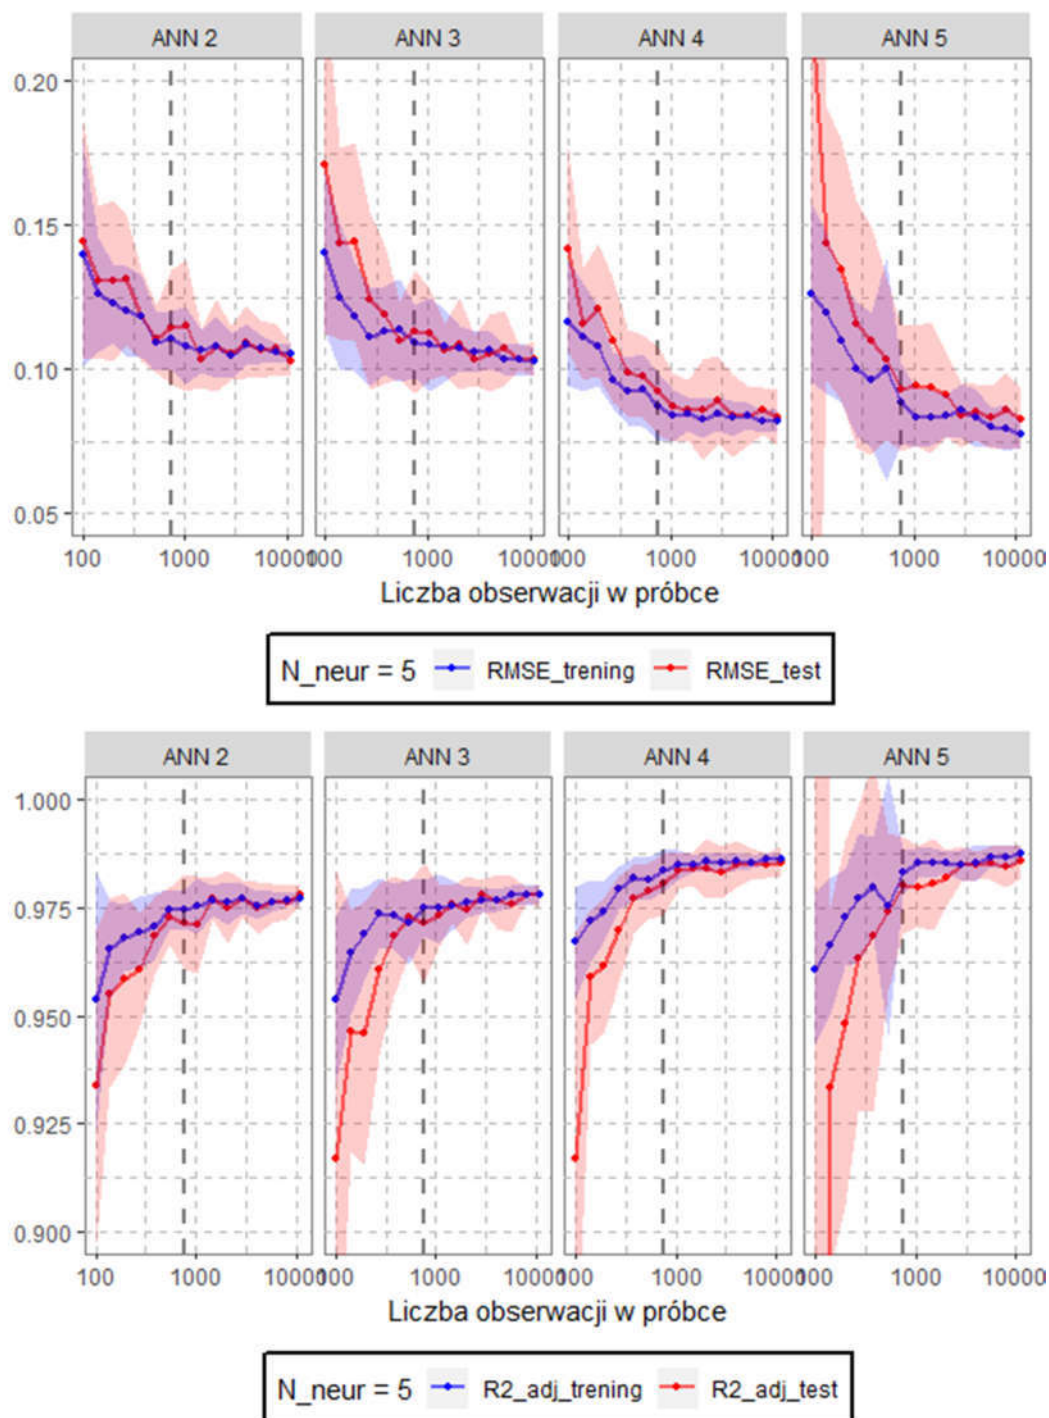
Model ANN 1 niezależnie od liczby neuronów oraz liczebności danych treningowych osiąga RMSE zbliżone do 0.300 g/s, a R_{adj}^2 do 0.800, co jest podobnym wynikiem do RW i KNN. Ponownie, model oparty jedynie na dwóch parametrach wejściowych okazuje się niewystarczający aby wiernie odwzorować pracę silnika w stanie dynamicznym, mimo zastosowania relatywnie skomplikowanego algorytmu jakim jest sztuczna sieć neuronowa.

Modeli z większą liczbą parametrów wejściowych uzyskują ponad 3 krotnie niższe RMSE, przy czym modele ANN 4 i ANN 5 zgodnie z oczekiwaniami osiągają najlepszą dokładność. Bardziej rozbudowana struktura sieci, tj. większa liczba neuronów w warstwie ukrytej wpływa na poprawę dokładności, przy czym należy uwzględnić dłuższy czas obliczeń oraz mniejszą interpretowalność modelu. Wybierając sieć o najmniej skomplikowanej strukturze ($N_{neu,ukr} = 5$) pozwala uzyskać satysfakcjonującą dokładność przy relatywnie prostym modelu.

Spśród dwóch najdokładniejszych modeli, ANN 4 i ANN 5, pierwszy wykazuje mniejszą wrażliwość na rozmiar danych treningowych. Zarówno RMSE oraz R_{adj}^2 , jak i ich odchylenie standardowe dla $l_{obs} < 750$ przyjmują odpowiednio niższe i wyższe wartości dla ANN 4. Można zatem uznać, że modelowanie procesu stanu pracy silnika w tym przypadku powinno opierać się na wartościach parametrów pracy w danej obserwacji oraz obserwacjach ją poprzedzających. Model opierający się na obserwacji oraz ($\Delta n, \Delta M$) osiąga minimalnie gorszą dokładność.




Rys. 9.21. $RMSE$ oraz R^2_{adj} w zależności od struktury sieci oraz liczby parametrów wejściowych. Modele wytrenowane na 600, testowane na 150 obserwacjach.




Rys. 9.22. $RMSE$ oraz R^2_{adj} w zależności od modelu oraz l_{obs} . Linia ciągła – wartości średnie dla 30 wyników, zacięniowany obszar – zakres \pm odchylenia standardowego. Wyniki dla modeli z $N_{neu,ukr} = 5$. Linia przerywana dla $l_{obs} = 750$.


Do dalszej analizy wybrany został model ANN 4 ze strukturą 8-5-1 (Rys. 9.24): 8 parametrami wejściowymi, 5 neuronami w warstwie ukrytej oraz jednym parametrem wyjściowym. Przykładową predykcję G_e dla modelu bazującego na $l_{obs} = 750$ przedstawiono na Rys. 9.25.



Rys. 9.23. $RMSE$ oraz R^2_{adj} w zależności od struktury sieci w ANN 1 (wyniki dla $l_{obs} = 750$) oraz w zależności od l_{obs} (wyniki dla $N_{neu,ukr} = 5$). Linia przerywana dla $l_{obs} = 750$. Uwaga: Oś y w innej skali w stosunku do Rys. 9.21 i Rys. 9.22.



Rys. 9.24. Struktura sztucznej sieci neuronowej przyjętej do dalszej weryfikacji metody.




Rys. 9.25. Zależność między wartościami G_e zmierzonymi a przewidywanymi przez model ANN 4 wytrenowany na 600, testowany na 150 obserwacjach ($l_{obs} = 750$).

9.8. Badanie weryfikacyjne – symulacja cyklu roboczego

9.8.1. Opis badania weryfikacyjnego

Badanie weryfikacyjne polegało na obciążeniu silnika poprzez wywołanie w układzie hydraulicznym stanowiska badawczego obciążenia przypominającego cykl roboczy zabudowy. Na podstawie przebiegu mocy hydraulicznej zarejestrowanemu w rzeczywistej śmieciarce, przyjęto cykl obciążenia trwający 30 s. Przebieg obciążenia zadawany przez układ sterowania i zrealizowany przez układ hydrauliczny stanowiska powodował reakcję silnika spalinowego, mającą na celu utrzymanie zadanej prędkości obrotowej. W rezultacie otrzymano przebieg mocy generowanej przez silnik (Rys. 9.26.)



Rys. 9.26. Przebieg rzeczywistej mocy odbieranej z silnika w jednym symulowanym cyklu.

Cykl obciążenia realizowany był dla każdej z prędkości obrotowej silnika z zakresu $n \in \{700, 750, 800, 850, 900, 950, 1000, 1050, 1100, 1150, 1200\}$. Badanie powtórzono

trzykrotnie. W rezultacie otrzymano 33 cykle obciążenia silnika, po trzy cykle dla każdej prędkości. Każdy cykl składał się z 300 punktów pomiarowych.

9.8.2. Obliczenia zużycia paliwa G_e

Do obliczenia G_e w każdym z przeprowadzonych cykli obciążeniowych wykorzystano 4 metody opisane w poprzednim podrozdziałach. Jako model referencyjny potraktowano regresję wielomianową uzyskaną z pomiarów w stanie statycznym. Pozostałe trzy modele wytrenowane zostały na danych z pomiarów w stanie dynamicznym (Tabela 15). Użyte zostały modele o zoptymalizowanych parametrach, na podstawie analizy przeprowadzonej w podrozdziale 9.5-9.7.

Tabela 15. Zestawienie weryfikowanych modeli wraz z przyjętymi parametrami.

Metoda	Oznaczenie modelu	Dane z treningowe	Parametry modelu	Parametry wejściowe
Regresja wielomianowa (statyczna)	REF	Z badania w stanie statycznym	Stopień wielomianu = 3	n, M
Regresja wielomianowa	RW	Z badania w stanie dynamicznym	Stopień wielomianu = 3	n, M
K-Najbliższych Sąsiadów	KNN		$k = 11$	$n, M, n_{500}, n_{1000}, n_{1500}, M_{500}, M_{1000}, M_{1500}$
Sztuczna Sieć Neuronowa	ANN		Struktura 8-5-1 Funkcja aktywacji: ReLu iteracje: 100	$n, M, n_{500}, n_{1000}, n_{1500}, M_{500}, M_{1000}, M_{1500}$

Modele RW, KNN oraz ANN zostały wytrenowane na 750 losowo wybranych obserwacjach z danych pomiarowych z testu dynamicznego. Trening oraz wybór losowych obserwacji powtórzono 30 razy, aby wyeliminować przypadkowość wyników. Model REF odpowiada modelowi uzyskanemu na podstawie testu statycznego nr 1 z podrozdziału 9.2. Wskaźniki dopasowania do danych treningowych zawiera Tabela 16. REF charakteryzuje się najlepszym dopasowaniem do danych treningowych, co wynika z natury testu w jakim dane zostały uzyskane. KNN oraz ANN zawierające 8 parametrów wejściowych osiągają również bardzo dobre wskaźniki dopasowania (R_{adj}^2 zbliżone do 1), mimo treningu na danych ze stanu dynamicznego. Regresja wielomianowa (RW) jest zdecydowanie najgorzej dopasowanym modelem, przy $R_{adj,tren}^2 = 0.820 g/s$ i $RMSE_{tren} = 0.301$.

Tabela 16. Wskaźniki dopasowania modeli do danych treningowych dla $l_{obs} = 750$ i 30 iteracji.

Wskaźnik	REF	RW	KNN	ANN
$R_{adj,tren}^2$	0.992	0.820 (0.010)	0.982 (0.004)	0.988 (0.004)
$RMSE_{tren}$	0.074	0.301 (0.011)	0.095 (0.008)	0.078 (0.011)

9.8.3. Omówienie wyników testu weryfikacyjnego


Po obliczeniu przewidywanego G_e , obliczone zostały wskaźniki dopasowania $RMSE$ oraz R_{adj}^2 dla każdego z cykli oraz wskaźniki przewidywania łącznego zużycia paliwa $\varepsilon_{\%cykl}$. Wyniki podsumowujące zawiera Tabela 17.

Wskaźniki dopasowania do danych z testu weryfikacyjnego są wyraźnie lepsze dla modeli KNN i ANN. R_{adj}^2 oraz $RMSE$ na poziomie odpowiednio 0.930 i 0.110 świadczą o bardzo dobrym dopasowaniu. Wskaźniki modeli opartych na regresji wielomianowej oscylują w okolicach 0.73 dla R_{adj}^2 i 0.231 g/s dla $RMSE$ (Rys. 9.27). Dopasowanie do rzeczywistego przebiegu G_e przedstawione zostało dla 4 wybranych n na Rys. 9.28. Dla REF oraz RW widoczne są miejsca z wyraźnie zaniżoną lub zawyżoną predykcją. Najlepiej dopasowanym kształtem przebiegu do rzeczywistego charakteryzuje się model ANN, a zaraz za nim KNN. Dzięki traktowaniu modelu jako proces stanu pracy silnika, możliwe jest dobre dopasowanie nawet w miejscach nagłych zmian G_e .


Weryfikacja metod pod kątem przewidywania łącznego zużycia paliwa prowadzi do oceny aplikacji metody w celach inżynierskich. REF bazująca na statycznej charakterystyce silnika, mimo relatywnie wysokiego $RMSE$ i nienajlepszego dopasowania do rzeczywistego przebiegu G_e , uzyskała średni $\varepsilon_{\%cykl,śr}$ bliski 0 dla 33 cykli roboczych. Skrajne wartości wynoszą -3.5% oraz 6.1% . Regresja wielomianowa bazująca na danych ze stanu dynamicznego (RW) również osiąga zadowalający $\varepsilon_{\%cykl,śr} = -0.5\%$, jednak jej odchyłki ($min = -10.6\%$ oraz $max = 12.2\%$) mogą wzbudzać obawy co do dokładności w przypadku predykcji w pojedynczych cyklach roboczych. Biorąc pod uwagę niewrażliwość modelu na zwiększenie liczby punktów treningowych, poprawa dokładności nie jest spodziewana. Modele KNN oraz ANN wykazują bardzo dobrą dokładność z $\varepsilon_{\%cykl,śr}$ na poziomie 2%, a ich odchyłki nie przekraczają $\pm 6\%$. Wyniki $\varepsilon_{\%cykl}$ w postaci wykresów skrzynkowych przedstawiono na Rys. 9.29.

Tabela 17. Wyniki aplikacji modeli do cykli roboczych z badania weryfikacyjnego. Wartości uśrednione dla 33 cykli. $l_{obs} = 750$ i 30 iteracji. W nawiasach podano odchylenie standardowe.


	REF	RW	KNN	ANN
$RMSE$	0.231	0.23 (0.028)	0.11 (0.032)	0.11 (0.037)
R_{adj}^2	0.727	0.73 (0.066)	0.93 (0.062)	0.93 (0.053)
$\varepsilon_{\%cykl,min}$ [%]	-3.5	-10.6	-5.5	-5.9
$\varepsilon_{\%cykl,śr}$ [%]	-0.1	-0.5 (3.69)	-1.9 (2.73)	-2 (3.42)
$\varepsilon_{\%cykl,max}$ [%]	6.1	12.2	2.9	3.3



Rys. 9.27. $RMSE$ oraz R^2_{adj} w zależności od modelu. Dla RW, KNN i ANN: $l_{obs} = 750$ i 30 iteracji.



Rys. 9.28. Przebieg G_e rzeczywisty (linie czarne) i przewidywany dla 4 wybranych prędkości n . W ramkach wartości $\varepsilon_{\%cycl}$.



Rys. 9.29. $\varepsilon_{\%cycl}$ w zależności od modelu. Dla RW, KNN i ANN: $l_{obs} = 750$ i 30 iteracji.

9.9. Podsumowanie

W rozdziale przedstawiony został proces weryfikacji metod odwzorowania charakterystyki silnika przy użyciu badań stanowiskowych. Wykonano pomiary parametrów pracy w stanie statycznym oraz w stanie dynamicznym, a uzyskane dane wykorzystano do wytrenowania modeli. Badanie weryfikacyjne, polegające na symulacji obciążenia cyklem roboczym zabudowy, pozwoliło ocenić przydatność metod w kontekście aplikacji do przewidywania zużycia paliwa w trakcie pracy zabudowy.

Charakterystyka silnika uzyskana na podstawie pomiarów w stanie statycznym pozwala na przewidywanie łącznego zużycia paliwa z wystarczającą dokładnością. Błąd procentowy łącznego zużycia paliwa nie przekracza 6%. Wykorzystanie tego samego algorytmu obliczeniowego do odwzorowania charakterystyki silnika przy użyciu danych uzyskanych w stanach dynamicznych prowadzi do błędów osiągających nawet 12%. Alternatywne metody zaproponowane w niniejszej pracy charakteryzują się znacząco dokładniejszym odwzorowaniem. Błędy procentowe przy użyciu metody k-Najbliższych Sąsiadów oraz Sztucznych Sieci Neuronowych, bazujących na danych z pomiarów w stanach dynamicznych, osiągają wartości nieprzekraczające 6%.

W kolejnym rozdziale metody zostały zastosowane przy użyciu danych z pomiarów trakcyjnych, przeprowadzonych w trakcie rzeczywistej pracy śmieciarki.

10. APLIKACJA METOD DO DANYCH Z POMIARÓW TRAKCYJNYCH

W poniższym rozdziale omawiane wcześniej metody odwzorowania charakterystyk zostały zastosowane do danych pochodzących z pomiarów trakcyjnych. Zaproponowano metodę selekcji punktów pomiarowych z uwagi na nierównomierny ich rozkład w polu pracy silnika. Modele regresji wielomianowej, K-Najbliższych Sąsiadów oraz Sztucznej Sieci Neuronowej wytypowane w poprzednim rozdziale użyte zostały do symulacji pracy silnika w 5 testowych przebiegach. Obliczone zużycie paliwa porównano z rzeczywistym, co pozwoliło na ocenę dokładności modeli. Wyniki przedstawiają również różnicę pomiędzy modelem nieuwzględniającym stanów dynamicznych (regresja wielomianowa) a modelami zawierającymi informację o przebiegu parametrów w czasie.


10.1. Przeprowadzone testy trakcyjne

Testy trakcyjne przeprowadzone zostały na śmieciarce Scania P280 DB6x2x4, z silnikiem o pojemności 9.3 dm^3 i mocy 206 kW (280 KM). Pojazd wyposażony był w zabudowę typu Medium XL z mechanizmem zasypowym SK350. Zarejestrowany został jeden pełny dzień pracy śmieciarki. Z danych pomiarowych odrzucone zostały obserwacje, w których silnik nie pracował w stanie rozgrzanym. Jako kryterium przyjęto temperaturę cieczy chłodzącej $< 70^\circ\text{C}$. Ponadto ze zbioru wyłączono zostało 5 20-sekundowych próbek (łącznie 1000 obserwacji) traktowanych w dalszych akapitach jako końcowe sprawdzenie modeli. W rezultacie czas pomiaru wyniósł 8 godzin, co przy próbkowaniu z częstotliwością 10 Hz pozwoliło uzyskać 290000 obserwacji.

Zaobserwowany rozkład punktów pomiarowych (Rys. 10.1) w polu pracy silnika jest typowy dla śmieciarek. Obserwacje z niewielkim $M = 100 \div 200 \text{ Nm}$ i $n = 600 \text{ obr/min}$ reprezentują postój pojazdu na biegu jałowym (obszar 1). Punkty w zakresie $n = 550 \div 650 \text{ obr/min}$ i $M > 200 \text{ Nm}$ odpowiadają w większości za pracę zabudowy podczas opróżniania pojemników (obszar 2). Pompa hydrauliczna jest włączona, a silnik pracuje z minimalną prędkością obrotową. Moc odbierana przez układ hydrauliczny mechanizmu zasypowego (wrzutnika) powoduje zwiększony moment obrotowy. Zagęszczenie obserwacji dla $n = 900 \text{ obr/min}$ (obszar 3) reprezentuje postój pojazdu i pełną pracę zabudowy, tj. zagęszczanie odpadów oraz opróżnianie pojemników. Prędkość silnika utrzymywana jest przez sterownik na fabrycznie ustawionej wartości (900 obr/min), co zapewnia zarówno zwiększoną podaż mocy jak i dostateczny przepływ oleju w układzie hydraulicznym.

Silnik badanego pojazdu pracował w obszarze 1 lub 2 przez około 50% czasu, a przez około 15% w obszarze 3. Zatem podczas analizowanego dnia pracy śmieciarki, pojazd poruszał się jedynie przez 35% czasu, w którym silnik spalinowy był włączony.

Należy przy tym zaznaczyć, że istnieje wiele typów zabudowy PUOP, wiele różnych tras przejazdu, rodzajów opróżnianych pojemników, strategii zbiórki odpadów itd. Zatem autor nie definiuje powyższej proporcji czasu pracy w poszczególnych obszarach pola pracy silnika jako typowej. Niemniej jednak, biorąc pod uwagę charakter pracy śmieciarki (tj. wielokrotne, krótkie przystanki w celu opróżnienia pojemników), podczas analizy innych tego typu pojazdów, należy spodziewać się podobnych zagęszczeń obserwacji w okolicach $n = n_{\text{jałowy}}$ i w okolicach ustawionej fabrycznie wartości n dla pracy zabudowy.




Rys. 10.1. Histogram 290000 obserwacji z pomiarów trakcyjnych w ciągu jednego dnia pracy pojazdu. Kolorem czarnym zaznaczone 3 typowe dla PUOP obszary w polu pracy (opis w tekście).

10.2. Metoda selekcji punktów pomiarowych

Zarejestrowane dane pomiarowe charakteryzują się wysoce nierównomiernym rozkładem w dziedzinie n i M . W przypadku zastosowania metody regresji wielomianowej oraz sztucznej sieci neuronowej, spodziewane jest nadmierne dopasowanie modelu do obszarów ze zdecydowanie wyższą koncentracją punktów pomiarowych. Spowoduje to uzyskanie modelu o mniejszej dokładności w przewidywaniu zużycia paliwa dla punktów z całego pola pracy silnika. Algorytm KNN nie wykazuje wrażliwości na rozkład obserwacji ponieważ przechowuje informacje o wszystkich danych wejściowych do modelu. Jednak zakładając losowe wydzielenie próbki o relatywnie niewielkim rozmiarze (np. 5%) z całego zbioru obserwacji, rozkład punktów pomiarowych próbki będzie niemal identyczny z rozkładem w zbiorze pierwotnym. Oznacza to, że utracona została duża część informacji o zużyciu paliwa w obszarach o niskim zagęszczeniu, co negatywnie wpływa również na dokładność KNN. Celowym jest zatem

przeprowadzenie selekcji punktów pomiarowych w celu uzyskania bardziej równomiernego rozkładu.


Zbiór punktów pomiarowych wykorzystany przy aplikacji metod odwzorowania charakterystyk silnika uzyskany został poprzez zastosowanie *losowania warstwowego* [134]. Na warstwy podzielony został zakres prędkości obrotowej silnika, następnie z każdej z nich losowo wybrana została równa liczba obserwacji. W przypadku gdy dana warstwa nie zawierała wystarczającej liczby obserwacji, wybrane zostały z niej wszystkie. W ten sposób uzyskano dwa zbiory danych: **zbiór I** poprzez wybór 10, a **zbiór II** 50 obserwacji z każdej warstwy. W efekcie zbiory zawierały odpowiednio 10990 oraz 51301 punktów pomiarowych. Porównanie rozkładów prędkości obrotowej oraz momentu w zbiorze przed i po losowaniu warstwowym prezentuje Rys. 10.2.



Rys. 10.2. Rozkład gęstości występowania punktów pomiarowych w dziedzinie n oraz M przed i po losowaniu warstwowym.

Zaproponowana przez autora metoda selekcji danych, polegająca na zastosowaniu losowania warstwowego skutkuje znaczącym zwiększeniem równomierności rozkładu punktów pomiarowych w dziedzinie n i M (Rys. 10.3), co pozwala na zminimalizowanie zjawiska nadmiernego lokalnego dopasowania modelu. W przypadku silnika spalinowego śmieciarki konieczne jest zwrócenie uwagi na specyfikę pracy badanego obiektu i zagęszczenie punktów pomiarowych w pewnych obszarach (obszary 1-3 na Rys. 10.1). Podstawowa metoda (polegająca na losowym wyborze punktów pomiarowych ze zbioru) okazuje się zatem niewystarczająca, podczas gdy metoda losowania warstwowego pozwala uzyskać zadawalający rozkład punktów. Metoda ta może być stosowana również w analizie danych trakcyjnych z innych silników spalinowych w pojazdach lub

urządzeniach, które ze względu na specyfikę pracy posiadają nierównomierny rozkład punktów pomiarowych w polu pracy silnika.




Rys. 10.3. Histogram obserwacji po losowaniu warstwowym (50 obs. z warstwy).

10.3. Modele RW, KNN i ANN obliczone na podstawie danych z pomiarów trakcyjnych

Na podstawie danych pomiarowych ze zbiorów I i II obliczone zostały modele regresji wielomianowej (RW), K-Najbliższych Sąsiadów (KNN) oraz Sztuczna Sieć Neuronowa (ANN). Przebieg parametrów pracy silnika (Rys. 10.4) zawiera przesunięcia czasowe Δt , typowe dla stanu dynamicznego. Zjawisko to zaobserwowano również w trakcie pomiarów na stanowisku badawczym. Modele KNN i ANN uwzględniają historię przebiegu n i M w celu zminimalizowania negatywnego wpływu Δt na dokładność predykcji G_e (Tabela 18).

Tabela 18. Parametry modeli trenowanych na danych z pomiarów trakcyjnych.

Model	Parametry modelu	Parametry wejściowe	Dane pomiarowe Treningowe / testowe	
			Zbiór I	Zbiór II
RW	Stopień wielomianu = 3	n, M	8792 / 2198 obserwacji	41041 / 10260 obserwacji
KNN	$k = 11$	$n, M, n_{500}, n_{1000}, n_{1500},$ $M_{500}, M_{1000}, M_{1500}$		
ANN	Struktura 8-5-1 Funkcja aktywacji: ReLu Iteracje: 100	$n, M, n_{500}, n_{1000}, n_{1500},$ $M_{500}, M_{1000}, M_{1500}$		



Rys. 10.4. Przebieg parametrów pracy silnika w trakcie pomiarów trakcyjnych z widocznymi przesunięciami czasowymi Δt .


Dane podzielone zostały losowo na dane treningowe i testowe w proporcji 80/20, a następnie obliczone zostały wskaźniki dokładności modelu: $RMSE_{training}$, $RMSE_{test}$, $R_{adj,training}^2$, $R_{adj,test}^2$. Aby wyeliminować wpływ podziału danych na wyniki, procedura powtórzona została 50 razy (50 iteracji). Średnie wartości wskaźników oraz ich odchylenia standardowe przedstawiono w Tabeli 19 oraz w postaci wykresów skrzynkowych przedstawiono na Rys. 10.5.

Tabela 19. Wskaźniki dokładności modeli trenowanych na danych z pomiarów trakcyjnych. Wartości średnie z 50 iteracji oraz ich odchylenie standardowe (w nawiasach).

	Zbiór I				Zbiór II			
	$RMSE_{tren}$ [g/s]	$RMSE_{test}$ [g/s]	$R_{adj,training}^2$	$R_{adj,test}^2$	$RMSE_{training}$ [g/s]	$RMSE_{test}$ [g/s]	$R_{adj,training}^2$	$R_{adj,test}^2$
RW	1.011 (0.006)	1.011 (0.024)	0.869 (0.002)	0.869 (0.007)	0.972 (0.003)	0.97 (0.011)	0.866 (0.001)	0.866 (0.003)
KNN	0.347 (0.007)	0.321 (0.024)	0.985 (0.001)	0.987 (0.002)	0.262 (0.003)	0.24 (0.011)	0.99 (0)	0.992 (0.001)
ANN	0.362 (0.013)	0.359 (0.033)	0.983 (0.001)	0.983 (0.003)	0.307 (0.022)	0.308 (0.024)	0.987 (0.002)	0.986 (0.002)

Model RW obliczony na podstawie zarówno zbioru zawierającego 8792 oraz 41041 obserwacji treningowych wykazuje zdecydowanie gorsze dopasowanie niż proponowane modele KNN oraz ANN. $RMSE_{test}$ równe odpowiednio 1.011 g/s oraz 0.972 g/s jest niemal trzykrotnie wyższe niż w porównywanych modelach. Podobna różnica widoczna jest we wskaźniku $R_{adj,test}^2$, gdzie wartości 0.869 i 0.866 są wyraźnie niższe niż dla ANN i KNN, których $R_{adj,test}^2$ jest zbliżone do 1. Dzięki licznemu zbiorowi

danych treningowych, model KNN wykazuje wyższą dokładność od ANN, a różnica zwiększa się dla modeli trenowanych na liczniejszym zbiorze II. $RMSE_{test}$ dla KNN i ANN wynoszą odpowiednio 0.321 g/s i 0.359 g/s (zbiór I) oraz 0.240 g/s i 0.308 g/s (zbiór II). Obydwa modele charakteryzują się bardzo wysokim $R^2_{adj, test}$, powyżej 0.983. Niewielkie różnice pomiędzy wynikami dla danych treningowych i testowych świadczą o poprawnym dopasowaniu modeli pod względem zjawiska overfitingu.



Rys. 10.5. R^2_{adj} oraz $RMSE$ obliczone na podstawie danych z pomiarów trakcyjnych ze zbioru I i II w 50 iteracjach.


10.4. Symulacja pracy silnika

10.4.1. Wyznaczenie przebiegów testowych

Przed losowaniem warstwowym, ze zbioru punktów pomiarowych wyodrębnione zostało 5 20-sekundowych przebiegów. Dzięki temu obserwacje w tych przebiegach nie zostały użyte do treningu modeli. Przebiegi zostały użyte jako końcowa weryfikacja modeli wytrenowanych na podstawie zbiorów I i II. Każdy z przebiegów został w sposób

celowy wybrany w taki sposób, aby reprezentował innych obszar pola pracy silnika lub inną realizowaną funkcję (Rys. 10.6). Przebieg nr 1 obejmuje zakres $1200 \div 1450 \text{ obr/min}$ i $200 \div 750 \text{ Nm}$ i odpowiada za jazdę pojazdu ze względnie niewielkim obciążeniem. Przebieg nr 2 reprezentuje pracę silnika w trakcie odbioru mocy przez układ hydrauliczny, w momencie gdy prędkość obrotowa podniesiona zostaje z 600 na 900 obr/min . Przebieg nr 3 obejmuje zakres $1100 \div 1250 \text{ obr/min}$ i szeroki zakres momentu obrotowego ($0 \div 1000 \text{ Nm}$) związany z jazdą. Przebiegi nr 4 i 5 reprezentują pracę silnika w trakcie jazdy w szerokim zakresie zarówno n jak i M , odpowiednio od 600 do 1450 i 1600 obr/min oraz od 0 do 900 i 1400 Nm .

Dla powyższych przebiegów obliczono przewidywane G_e oraz porównano je z rzeczywistymi zarejestrowanymi wartościami przy użyciu względnego błędu procentowego łącznego zużycia paliwa ε_0 .



Rys. 10.6. Przebiegi testowe w polu pracy silnika, wyodrębnione przed treningiem, w celu końcowej weryfikacji modeli.


10.4.2. Wyniki końcowej weryfikacji modeli

Względny błąd procentowy ε_0 obliczony został dla każdego z modeli dla każdej z 50 iteracji (analogicznie do obliczeń wskaźników dokładności z podrozdziału 10.3). Uzyskano w ten sposób wartości średnie oraz odchylenia standardowe, które pozwalają dostrzec wrażliwość modelu na dane treningowe. Wyniki przedstawiono w Tabeli 20 oraz w postaci wykresów skrzynkowych na Rys. 10.7.

Model regresji wielomianowej charakteryzuje się wysokimi bezwzględnymi wartościami ε_0 , nawet do 16.2%. Jedynie dla przebiegów nr 4 i 5 spada poniżej 5%. Model

KNN oraz ANN osiągają satysfakcjonującą ε_0 poniżej 5% dla treningu na zbiorze II, i poniżej 6% dla treningu na zbiorze I. Dodatkowo, przebieg przewidywanego G_e w czasie dla tych modeli niemal pokrywa się z rzeczywistym (Rys. 10.8), podczas gdy przebieg dla RW, nawet mimo niewielkiego ε_0 , wykazuje wyraźne rozbieżności względem rzeczywistego. Jest to dodatkowe potwierdzenie celowości stosowania alternatywnych metod w celu wyznaczania charakterystyki silnika z danych uzyskanych w stanach dynamicznych.


Wyniki dla modeli trenowanych zarówno na zbiorze I jak i zbiorze II nie wykazują znaczących różnic. Większa liczebność zbioru danych treningowych nie przekłada się w znaczący sposób w tym przypadku na zwiększoną dokładność w postaci mniejszego ε_0 .



Rys. 10.7. Względny błąd przewidywanego łącznego zużycia paliwa ε_0 dla 5 symulowanych przebiegów.

Tabela 20. średni $\varepsilon_{\%}$ oraz odchylenie standardowe (w nawiasach) w 50 iteracjach dla pięciu przebiegów i trzech modeli trenowanych na zbiorach I i II.

Nr przebiegu	$\varepsilon_{\%}$ [%]					
	Trenowane na zbiorze I			Trenowane na zbiorze II		
	ANN	KNN	RW	ANN	KNN	RW
1	-2.3 (1.8)	-2.6 (0.3)	-7.1 (0.3)	-2.3 (2.1)	-3.2 (0.2)	-6.9 (0.2)
2	0.5 (2.4)	2.3 (0.1)	15.8 (0.3)	0.1 (3.4)	1.2 (0.1)	16.2 (0.1)
3	-5.8 (1.6)	-3.1 (0.4)	-7.7 (0.4)	-4.8 (1.4)	-3.1 (0.2)	-7.3 (0.1)
4	-0.6 (3)	1.6 (0.3)	4.4 (0.2)	0.1 (2.3)	1.2 (0.2)	4.1 (0.1)
5	2.5 (1.6)	1.8 (0.4)	3.8 (0.2)	3.0 (1.5)	1.5 (0.3)	3.6 (0.1)



Rys. 10.8. Porównanie przebiegu przewidywanego i rzeczywistego G_e (linia czarna) dla iteracji nr 20. W ramach $\varepsilon_{\%}$. Model trenowany na zbiorze II.

11. OCENA SPRAWNOŚCI UKŁADU NAPĘDOWEGO ŚMIECIARKI

Rozdział prezentuje zastosowanie modelu silnika spalinowego uzyskanego przy użyciu przeanalizowanej w poprzednich rozdziałach metody odwzorowania charakterystyki silnika z wykorzystaniem Sztucznej Sieci Neuronowej. Na podstawie danych pochodzących z eksploatacji pojazdu zdefiniowane zostały 4 referencyjne cykle robocze pracy zabudowy śmieciarki oraz określono energię układu hydraulicznego zużytą podczas każdego z nich na podstawie przebiegu mocy w układzie hydraulicznym. Następnie określono zależności pomiędzy rejestrowanym momentem obrotowym, a rzeczywistym momentem obrotowym dostępnym na przystawce odbioru mocy. W efekcie możliwe było uzyskanie przebiegów momentu w zależności od czasu, a następnie zasymulowanie zużycia paliwa w danym cyklu. Dla prędkości obrotowych z zakresu 700 – 1200 obr/min obliczono łączne zużycie paliwa w cyklach. Porównując energię hydrauliczną cyklu z energią ze zużytego paliwa, obliczone zostały sprawności poszczególnych konfiguracji układów napędowych. Zaprezentowana metoda analizy energetycznej pozwoliła na ocenę sprawności układu napędowego, wzajemne porównanie konfiguracji jak również ocenę sprawności poszczególnych cykli roboczych śmieciarki.

11.1. Cykle robocze pracy zabudowy śmieciarki

Model obliczeniowy silnika spalinowego w pojeździe użytkowym może być wykorzystany do symulowania zużycia paliwa, zużycia energii oraz oceny sprawności pojazdu. Poniżej przeanalizowano cztery cykle obciążenia pracy śmieciarki (Tabela 21) pochodzące z rzeczywistej eksploatacji pojazdu. Zostały one wykorzystane do obliczenia łącznego zużycia paliwa w cyklu w zależności od prędkości obrotowej silnika spalinowego. Prędkość ta, ustawiana fabrycznie przez producenta zabudowy, zdeterminowana jest przez konfigurację układu napędowego dostarczającego moc do układu hydraulicznego. Na podstawie wyników symulacji dokonano oceny efektywności energetycznej poszczególnych konfiguracji.

Cykl obciążenia określony jest parametrami:

E_{cykl} – energia hydrauliczna cyklu

\bar{P}_{cykl} – średnia moc hydrauliczna w cyklu

t_{cykl} – czas trwania cyklu

Przy czym powyższe parametry określone są zależnościami:

$$E_{cykl} = \sum_{i=1}^m (P_i \cdot \Delta t) \quad (11.1)$$

$$t_{cykl} = m \cdot \Delta t \quad (11.2)$$

$$\bar{P}_{cykl} = \frac{E_{cykl}}{t_{cykl}} \quad (11.3)$$


Gdzie P_i jest chwilową mocą hydrauliczną w chwili pomiaru t_i , Δt jest czasem pomiędzy kolejnymi obserwacjami, m jest liczbą obserwacji w rozpatrywanym cyklu.

Przebiegi na

Rys. 11.1 przedstawiają moc w układzie hydraulicznym podczas wykonywania przez zabudowę podstawowych czynności eksploatacyjnych. Chwilowa moc P_i jest sumą mocy dwóch obiegów hydraulicznych, uzyskana dzięki znajomości prędkości kątowej silnika ω_s i ciśnień p_1 i p_2 na wyjściach pompy do odpowiednio dużego i małego obiegu:

$$P_i = r_{PTO} \cdot \omega_s \cdot q_1 \cdot p_1 + r_{PTO} \cdot \omega_s \cdot q_2 \cdot p_2 \quad (11.4)$$

Gdzie r_{PTO} to przełożenie przystawki, q_1 i q_2 to pojemności jednostkowe dwusekcyjnej pompy hydraulicznej.



Rys. 11.1. Moc odbierana z silnika podczas pracy zabudowy śmieciarki w czterech referencyjnych cyklach roboczych.

Wszystkie cykle odbywają się w czasie postoju pojazdu. Cykl 1 zawiera czas oczekiwania na uruchomienie mechanizmu zasypowego oraz następującą po nim pracę mechanizmu zasypowego w celu opróżnienia pojemnika. Charakteryzuje się niskim średnim poborem mocy (4.34 kW) w trakcie 28 sekund. Cykl 2 przedstawia pojedynczy

cykl prasy hydraulicznej podczas zagęszczania odpadów. Jest najkrótszym rozpatrywanym cyklem (17 s) o najwyższym średnim poborze mocy równym 22.3 kW. Cykl 3 składa się z oczekiwania, następnie pracy mechanizmu zasypowego, kolejno zagęszczaniu odpadów, a w końcowej fazie oczekiwania na wyłączenie pompy i ruszenie pojazdu. Długi czas oczekiwania skutkuje 54 sekundowym cyklem o relatywnie niskim średnim poborze mocy równym 7 kW. Cykl 4 to oczekiwanie, opróżnianie pojemników, następnie zagęszczanie i ponowne opróżnianie z zagęszczaniem. W końcowej fazie widoczne jest oczekiwanie na wyłączenie pompy. W rezultacie jest to najdłuższy cykl (80 s) o średnim poborze mocy równym 10.9 kW. Powyższe cykle są typowymi dla pracy śmieciarki tylnozładowniczej i mogą być traktowane jako referencyjne w dalszych analizach układu napędowego.

Tabela 21. Szczegóły cykli obciążenia silnika.

	t_{cykl}	\bar{P}_{cykl}	E_{cykl}	Opis
Cykl 1	28 s	4.34 kW	122 kJ	Oczekiwanie, opróżnianie pojemników
Cykl 2	17 s	22.3 kW	379 kJ	Zagęszczanie
Cykl 3	54 s	7.0 kW	378 kJ	Oczekiwanie, opróżnianie, zagęszczanie
Cykl 4	80 s	10.9 kW	872 kJ	Oczekiwanie, opróżnianie, zagęszczanie

11.2. Zależność M od M_s i n


Aby wykorzystać model obliczeniowy silnika uzyskany z danych eksploatacyjnych w sposób omówiony w poprzednich rozdziałach, konieczne jest ustalenie zależności pomiędzy momentem rejestrowanym w magistrali CAN a momentem na kole zamachowym silnika i prędkością obrotową:

$$M = f(M_s, n) \quad (11.5)$$

Na podstawie pomiarów wykonanych na stanowisku badawczym wyposażonym w czujnik momentu obrotowego pomiędzy przystawką a pompą, znaleziona została zależność w postaci funkcji liniowej:

$$M = 1.38 \cdot M_s + 0.118 \cdot n + 37.19 \quad (11.6)$$

Współczynnik R_{adj}^2 dla powyższego dopasowania wyniósł 0.947 a każdy ze współczynników był statystycznie znaczący ($p < 0.05$). Warto zauważyć, że wraz ze wzrostem prędkości silnika zwiększa się różnica pomiędzy momentami (Rys. 11.2).



Rys. 11.2. M rejestrowany z magistrali CAN w zależności od rzeczywistego momentu obrotowego na kole zamachowym.

11.3. Przebieg M w zależności od n

Ustalona zależność (2) pozwala na obliczenie przebiegu M w czasie dla danej n w zależności od mocy P w chwili i , zgodnie ze wzorem:

$$M_i = \frac{P_i}{n \cdot \frac{2\pi}{60}} \quad (11.7)$$

Uzyskane wartości M wraz z n stanowią dane wejściowe do modelu obliczeniowego silnika. Dokonywane jest przy tym uproszczenie, polegające na przyjęciu stałej wartości n w poszczególnych symulacjach. W trakcie rzeczywistej pracy silnika prędkość oscylowałaby wokół zadanej wartości, a jej zmiany byłyby proporcjonalne do zmian momentu, jednak wpływ tych zmian został pominięty.

11.4. Obliczenie łącznego zużycie paliwa w cyklach roboczych

Wykorzystując model sztucznej sieci neuronowej (ANN) uzyskany na podstawie 51301 obserwacji z danych eksploatacyjnych, według metody omówionej w poprzednim rozdziale, obliczone zostało G_e dla każdego z analizowanych cykli, oraz dla każdej prędkości obrotowej ze zbioru:

$$\{700, 750, 800, 850, 900, 950, 1000, 1050, 1100, 1150, 1200\} \text{ obr/min.}$$

Następnie obliczone zostało łączne zużycie paliwa w cyklu Z , zdefiniowane wzorem:

$$Z = \sum_{i=1}^m (G_{e,i} \cdot \Delta t) \quad (11.8)$$

Gdzie m jest liczbą punktów pomiarowych, a Δt krokiem czasowym. Wyniki obliczeń łącznego zużycia paliwa przedstawiono na Tabeli 22 oraz Rys. 11.3. Obliczona została również energia E pochodząca z paliwa:

$$E_{pal} = Z \cdot Q \quad (11.9)$$

Gdzie Q jest wartością opałową oleju napędowego i wynosi 43 MJ/kg [135].


Dla śmieciarki tylnozaladowczej proces opróżnienia pojemnika poprzedzony 10 sekundowym oczekiwaniem na przygotowanie pojemnika przez operatora (cykl 1) wymaga od 863 kJ do 1674 kJ (zużycie od 20.1 do 38.9 g paliwa). Zagęszczanie odpadów z uwagi na wysoką średnią moc i brak oczekiwania (cykl 2) charakteryzuje się mniejszym rozrzutem, i wymaga od 1483 do 1692 kJ ($34.5 \div 39.3 \text{ g}$ paliwa). Pełen pojedynczy cykl pracy śmieciarki od momentu zatrzymania do ruszenia (cykl 3) zużywa od 2138 do 3730 kJ energii ($49.7 \div 86.8 \text{ g}$ paliwa). Z kolei podwójny cykl opróżniania i zagęszczania podczas jednego postoju wymaga 4344 do 6474 kJ energii ($101 \div 150.6 \text{ g}$ paliwa).

Tabela 22. Łączne zużycie paliwa w cyklu w zależności od ustawionej prędkości silnika.

n [obr/min]	Z [g]				E [kJ]			
	Cykl 1	Cykl 2	Cykl 3	Cykl 4	Cykl 1	Cykl 2	Cykl 3	Cykl 4
700	20.1	34.5	49.7	101.0	863	1483	2138	4344
750	21.7	35.6	53.2	106.3	934	1530	2286	4571
800	23.5	36.6	57.0	110.8	1009	1575	2449	4764
850	25.3	37.3	61.1	115.2	1087	1604	2629	4954
900	27.2	37.9	64.8	119.8	1169	1631	2785	5153
950	29.1	38.1	68.1	124.3	1252	1637	2928	5345
1000	31.1	38.2	71.6	129.3	1338	1644	3080	5560
1050	33.2	38.6	75.3	134.4	1426	1660	3238	5781
1100	35.2	39.3	79.1	139.7	1515	1690	3400	6007
1150	37.3	40.1	83.1	145.2	1605	1726	3572	6244
1200	38.9	39.3	86.8	150.6	1674	1692	3730	6474

Biorąc pod uwagę fakt, iż w większości produkowanych śmieciarek układ napędowy skonfigurowany jest sposób wymuszający fabryczne ustawienie prędkości obrotowej na poziomie 1000 lub 900 obr/min , warto zwrócić uwagę na porównanie zużycia energii tych konfiguracji z tą, gdzie prędkość silnika wynosiła 800 obr/min (Tabela 23). Procentowe różnice względem $n = 1000 \text{ obr/min}$ wynoszą od 4% w cyklu 2, aż do 33% w cyklu 1. W przypadku $n = 900 \text{ obr/min}$ różnice są mniejsze, od 4% do 16% . Największe korzyści wynikające z ustawienia niższej prędkości obrotowej zaobserwować można w cyklach o niskim średnim poborze mocy i/lub relatywnie długimi czasami

oczekiwania na opróżnianie lub zagęszczanie. Skrajny przypadek konfiguracji z pompą o małej pojemności jednostkowej i $n = 1200 \text{ obr/min}$ prowadzi do nieekonomicznej pracy silnika i powoduje wzrost zużycia energii od 7% aż do 66% w porównaniu z konfiguracją z $n = 800 \text{ obr/min}$.



Rys. 11.3. Łączne zużycie paliwa Z w cyklu w zależności od ustawionej prędkości silnika.

Tabela 23. Różnice w łącznym zużyciu paliwa w cyklu w porównaniu ze zużyciem dla $n = 800 \text{ obr/min}$.

n [obr/min]	% różnica			
	Cykl 1	Cykl 2	Cykl 3	Cykl 4
700	-14%	-6%	-13%	-9%
750	-7%	-3%	-7%	-4%
800	0%	0%	0%	0%
850	8%	2%	7%	4%
900	16%	4%	14%	8%
950	24%	4%	20%	12%
1000	33%	4%	26%	17%
1050	41%	5%	32%	21%
1100	50%	7%	39%	26%
1150	59%	10%	46%	31%
1200	66%	7%	52%	36%

11.5. Ocena sprawność układu napędowego

Dzięki obliczonej energii pochodzącej z zużytego paliwa oraz znanej energii cyklu możliwe było określenie sprawności eksploatacyjnej układu napędowego zabudowy η_{ex} (Tabela 24 oraz Rys. 11.4), która w tej sytuacji określona jest wzorem:

$$\eta_{ex} = \frac{E_{cykl}}{E_{pal}} \cdot 100\% \quad (11.10)$$


W obliczeniach założono brak akumulacji energii kinetycznej i potencjalnej w układzie względem stanu przed i po cyklu.

Sprawność eksploatacyjna układu napędowego śmieciarki nie przekracza 26%. Dla najniższej prędkości obrotowej i dużego obciążenia silnika pracą prasy hydraulicznej η_{ex} zawiera się w przedziale $22.4 \div 25.6\%$. Proces opróżniania pojemnika z cyklu 1 charakteryzuje się sprawnością w granicach $7.3 \div 14.1\%$. W pełnych cyklach roboczych (3 i 4) η_{ex} przyjmuje wartości odpowiednio $10.1 \div 17.7\%$ i $13.5 \div 20.1\%$. Biorąc pod uwagę maksymalną możliwą sprawność silnika ZS równą 45%, oczywistym jest, iż w czasie pracy zabudowy silnik nie jest wykorzystywany w sposób optymalny.

W typowych konfiguracjach ($n = 900$ i 1000 obr/min) sprawności dla cykli 3 i 4 wynoszą odpowiednio 13,6% i 12,3% oraz 16,9% i 15,7%.

Tabela 24. Sprawność eksploatacyjna układu napędowego w cyklu roboczym.

n [obr/min]	η_{ex}			
	Cykl 1	Cykl 2	Cykl 3	Cykl 4
700	14.1%	25.6%	17.7%	20.1%
750	13.0%	24.8%	16.5%	19.1%
800	12.0%	24.1%	15.4%	18.3%
850	11.2%	23.6%	14.4%	17.6%
900	10.4%	23.2%	13.6%	16.9%
950	9.7%	23.2%	12.9%	16.3%
1000	9.1%	23.1%	12.3%	15.7%
1050	8.5%	22.8%	11.7%	15.1%
1100	8.0%	22.4%	11.1%	14.5%
1150	7.6%	22.0%	10.6%	14.0%
1200	7.3%	22.4%	10.1%	13.5%



Rys. 11.4. Sprawność eksploatacyjna układu napędowego w cyklu roboczym.

11.6. Zastosowanie metody

Przedstawiona w tym rozdziale metoda analizy energetycznej cyklu roboczego pozwala na ilościową ocenę korzyści, jakie niesie ze sobą optymalne skonfigurowanie układu napędowego. Zakładając, że użytkownik śmieciarki zna charakterystykę regionu, w którym pojazd jest eksploatowany, możliwe jest oszacowanie liczby cykli roboczych oraz średniej mocy hydraulicznej cyklu, odwołując się do omówionych powyżej cykli referencyjnych. Pod pojęciem charakterystyki regionu należy tu rozumieć m.in. wzajemne rozmieszczenie pojemników, frakcję zbieranych odpadów, czy też średnią masę odpadów w pojedynczym pojemniku. Dane te pochodzić mogą z nowoczesnych systemów zarządzania flotą pojazdów i charakteryzować się wysoką dokładnością. Można również skorzystać z ogólnych danych (np. łączna masa odpadów) oraz doświadczenia użytkownika. Oszacowana liczba cykli oraz średnia moc umożliwi obliczenie łącznego zużycia paliwa przez pojazd w ciągu dnia, tygodnia czy miesiąca pracy. Prowadzi to oczywiście to obliczenia kosztów eksploatacji śmieciarki pod kątem zużycia paliwa potrzebnego do realizacji funkcji zabudowy. Przedstawiona metoda umożliwia bezpośrednią ocenę korzyści finansowych jakie niesie ze sobą lepsza konfiguracja układu napędowego. W tym miejscu należy wspomnieć, że różne konfiguracje mogą się różnić pod względem kosztu podzespołów oraz kosztów serwisowania, jednak różnice te są nieznaczne w stosunku do różnic w zużyciu paliwa.

Według wiedzy autora, dotychczas nie została opracowana analiza podobna do przedstawionej w tej pracy. Użytkownicy jak i producenci pojazdów użytkowych skupiają się na ekonomice jazdy pojazdu i zużyciu paliwa związanego z transportem. Mniejsza uwaga skierowana jest na zużycie energii przez elementy wykonawcze zabudowy. Z przedstawionych danych (Rozdział 8) wynika, że silnik spalinowy śmieciarki w ciągu 8 godzinnego dnia pracy, przez około 50% czasu pracuje z prędkością 600 obr/min, a więc podczas postoju. 15% czasu stanowi praca z $n=900$ obr/min wymuszona przez zabudowę, również podczas postoju. Zatem pojazd pozostawał w ruchu jedynie podczas 35% czasu. Przekłada się to na stosunek łącznego zużycia paliwa 35% postój / 65% jazda (odpowiednio 20 dm^3 i 40 dm^3). Tak wysoki udział zużycia paliwa podczas postoju w pełni uzasadnia konieczność optymalizacji układu napędowego zabudowy.

12. UWAGI KOŃCOWE I WNIOSKI

Jako rezultat przeprowadzonych w niniejszej pracy teoretycznych rozważań na temat metod odwzorowania charakterystyk silnika spalinowego, analizy stanów statycznych i dynamicznych, testów stanowiskowych, pomiarów trakcyjnych oraz aplikacji opracowanej metody do optymalizacji układu napędowego sformułowano poniższe uwagi i wnioski.

Teza pracy została potwierdzona poprzez opracowaniu metody, która umożliwia odwzorowanie charakterystyki silnika z wymaganą dokładnością, tj. błędem przewidywania zużycia paliwa mniejszym niż 7%. Metoda wykorzystuje dane pomiarowe pochodzące z bieżącej eksploatacji pojazdu, rejestrowane bezpośrednio z magistrali CAN bez użycia specjalistycznej aparatury.

W pracy wykonano analizę wpływu zastosowanego kryterium kwalifikacji punktów pracy silnika do stanów statycznych, zarejestrowanych w czasie regularnej eksploatacji, na liczbę i rozkład tych punktów. Wynika z niej, że liczba tych punktów jest znikoma, a ich rozmieszczenie w polu pracy silnika jest nierównomierne. Niemożliwym jest zatem uzyskanie statycznej charakterystyki silnika na bazie takich pomiarów i konieczne jest użycie innej metody odwzorowania własności energetycznych silnika, która nie wymaga traktowania wybranych punktów pracy silnika jako dozorowanie stanów statycznych.

Zaproponowane zostały trzy metody: aproksymacja funkcją wielomianową, która wykorzystywana jest w charakterystykach statycznych; poszukiwanie stanów podobnych (KNN); sztuczna sieć neuronowa (ANN). Dane wejściowe do każdej z nich traktowane były jako punkty pomiarowe w danej chwili (z historią lub bez), z pominięciem podziału na statyczne i dynamiczne. Z uwagi na tendencję do nadmiernego dopasowywania się modelu do obszarów w polu pracy silnika, gdzie występują nagromadzenia punktów pomiarowych, konieczne było opracowanie procedury selekcji danych, tak aby uzyskany rozkład punktów w dziedzinie prędkości i momentu obrotowego był bardziej równomierny. Zadawalający rezultat uzyskano stosując metodę losowania warstwowego.

Eksperymenty przeprowadzone na stanowisku testowym pozwoliły stwierdzić, że zastosowanie aproksymacji funkcją wielomianową prowadzi do błędów w prognozowaniu łącznego zużycia wynoszących nawet 12%. Metody KNN oraz ANN charakteryzowały się błędami mniejszymi niż 6%. Prognoza zużycia paliwa w cyklu roboczym na bazie statycznej charakterystyki silnika (możliwej do uzyskania jedynie w testach stanowiskowych, w stanach statycznych) również uzyskała zadawalającą dokładność (błąd mniejszy niż 6%). Stanowisko pomiarowe umożliwia uzyskiwanie zarówno statycznych jak i dynamicznych punktów pomiarowych. Należy przy tym

zaznaczyć, że pomiary prowadzone w stanach statycznych są bardziej czasochłonne i wymagają większej ilości paliwa. Rezultaty przedstawione w tej pracy pokazują, że przeprowadzanie krótszego testu składającego się ze stanów dynamicznych i zastosowanie alternatywnej metody (ANN) skutkuje zbliżoną (a nawet wyższą) dokładnością modelu, minimalizując tym samym nakłady konieczne do uzyskania charakterystyki silnika. Oznacza to, że mając do dyspozycji pojazd użytkowy, możliwe jest szybkie zebranie danych (z magistrali CAN) w trakcie normalnej eksploatacji i przy użyciu przedstawionej w pracy metody ANN uzyskanie charakterystyki silnika spalinowego. Taka charakterystyka pozwala na prognozowanie zużycia paliwa dla dowolnego obciążenia lub cyklu roboczego zadowalającą dokładnością.

Uzyskany model silnika spalinowego z pomiarów trakcyjnych umożliwił ocenę sprawności eksploatacyjnej układu napędowego, która nie przekracza 26%. W pracy zdefiniowane zostały referencyjne 4 cykle robocze śmieciarki. Ich analiza przy wykorzystaniu powyższego modelu pozwala na optymalizację konstrukcji układu napędowego oraz ilościową ocenę korzyści takiej optymalizacji. Przykładowo, modyfikując popularną konstrukcję układu (zakładając pracę silnika z prędkością $n = 1000 \text{ obr/min}$), na konstrukcję gdzie $n = 800 \text{ obr/min}$ zużycie paliwa zmniejsza się o od 4% do 33% w zależności od cyklu. W skrajnych przypadkach zużycie paliwa może zostać zredukowane nawet o 66%.

Modele uzyskane dla różnych pojazdów użytkowych umożliwiają obliczenie sprawności eksploatacyjnej ich układów napędowych w danym, tym samym cyklu referencyjnym. Prowadzi to do wzajemnego porównania pojazdów pod kątem energetycznym i wskazania, który pojazd jest bardziej odpowiedni (pod kątem zużycia paliwa) do wykonywania poszczególnych zadań. Przedstawiona w pracy metoda umożliwia zatem daleko idącą analizę floty pojazdów, wymagając jedynie przeprowadzenia krótkich, nie wymagających ingerencji w konstrukcje i elektronikę pojazdu pomiarów.

Literatura

1. Chłopek Z: Some remarks on engine testing in dynamic states, *Combustion Engines*, (4), pp. 61–71, 2010
2. Cichy M: Silniki o działaniu cyklicznym, Wydawnictwo Politechniki Gdańskiej, Gdańsk 1987
3. Kneba Z, Makowski S: Zasilanie i sterowanie silników, WKŁ, 2004
4. Cichy M: Modelowanie systemów energetycznych, Wydawnictwo Politechniki Gdańskiej, Gdańsk, 2001.
5. Kropiwnicki J: Modelowanie układów napędowych pojazdów z silnikami spalinowymi, Gdańsk, 2016
6. Scania Bodybuilding Information: Informacje ogólne o przystawkach odbioru mocy, Wydanie 5, 2013
7. MAN Truck & Bus AG: MAN Guidelines to fitting bodies Truck, 2016
8. Body Builder Management Mercedes-Benz Trucks: Technical Information for Body Builder, Germany 2013
9. Borkowski T: Śmieciarka śmieciarce Cz. I-IV, *Przegląd Komunalny*, (5), pp. 78–80, 2012
10. Czyżewicz, J: Badania procesu załadunku śmieci i modyfikacja układu sterowania mechanizmu załadunkowego śmieciarki, Praca doktorska, Politechnika Gdańska, 2011
11. Strona producenta zabudów śmieciarek Hidromak www.hidromak.com/en/a/articles/10/rear-loaded-garbage-body-parts, data dostępu: 5.10.2019
12. The Unofficial Shelvoke & Drewry Website.” <http://www.shelvoke-drewry.co.uk/>, data dostępu 13.10.2011
13. Paynter HM: Analysis and Design of Engineering Systems, The MIT Press Cambridge, Massachusetts, 1961.
14. Wellstead PE: Introduction to System Modeling, Academic Press, London, 1979.
15. Karnopp DC, Rosenberg RC: System Dynamic: A Unified Approach, Wiley, New York, 1975.
16. Czyżewicz J, Wasilczuk M: Wpływ oporów ruchu odpadów w skrzyni zbiorczej pojazdu do usuwania odpadów z pojemników na parametry procesu prasowania, *Tribologia*, nr. 1(259), s.25-36, 2015
17. Zimmermann W, Schmidgall R: Magistrale danych w pojazdach. Protokoły i standard, Wydanie 1 WKŁ, Warszawa 2008
18. Jarosz T.: Problematyka analizy danych w magistrali CAN w pojazdach samochodowych, *Czasopismo Techniczne, Politechniki Krakowskiej*, 18:75–84, 2012
19. Jajczyk J, Matwiejczyk K: Diagnostyka magistrali CAN w pojazdach, *Poznań University Of Technology Academic Journals*, nr 79, 2014
20. Plich M, Szypowski P: Eksploatacyjne właściwości magistrali CAN w pojazdach samochodowych, *Czasopismo Techniczne, Politechnika Krakowska*, nr 18, 2012
21. SAE J1939 Standards
22. FMS-Standard description Version 04, www.fms-standard.com/Truck, data dostępu 20.12.2018
23. Strona internetowa Xtrack <http://xtrack.com>, data dostępu 5.10.2019
24. Holzleitner F, Kanzian C, Stampfer K: Analyzing time and fuel consumption in road transport of round wood with an onboard fleet manager. *European Journal of Forest Research*, 130(2), pp. 293–301, 2011
25. Holzleitner F, Kanzian C, Höller N: Monitoring the chipping and transportation of wood fuels with a fleet management system, *Silva Fennica*, nr 47, pp. 1-11, 2013
26. Léonardi J, Baumgartner M: CO2 efficiency in road freight transportation: Status quo, measures and potential, *Transportation Research Part D: Transport and Environment*, Vol 9, nr 6, ss. 451-464, 2004
27. Walnum HJ, Simonsen M: Does driving behavior matter? An analysis of fuel consumption data from heavy-duty trucks. *Transp Res Part D*, 36:107–20, 2015

28. Liimatainen H: Utilization of Fuel Consumption Data in an Ecodriving Incentive System for Heavy-Duty Vehicle Drivers, *IEEE Transactions on Intelligent Transportation Systems*, vol. 12, nr 4, ss 1087-1095, 2011
29. Devlin G, Klvac R, Mcdonnell K: Fuel efficiency and CO 2 emissions of biomass based haulage in Ireland: A case study, 54:55–62, 2013
30. Tacke J, Sanchez Rodrigues, V, Mason R: Decarbonisation initiatives applied within the german logistics sector, 16th International Symposium on Logistics (ISL 2011) Berlin, Germany, 2011
31. Summary of Fleet Management in Europe – 8th Edition, <https://www.prnewswire.com/news-releases/fleet-management-in-europe---8th-edition-228006261.html>, data dostępu 10.06.2019.
32. Strona producenta Parker <https://ph.parker.com/us/21051/en/air-oil-coolers-acd>, data dostępu 5.10.2019
33. Zieliński T: Cyfrowe przetwarzanie sygnałów, WKL, 2016
34. Grzeszczyk R, Merkiś J, Drop T, Kamiński T, Niezgodą M, Rychter M, et al.: Model-based Digital Filtering Utilised in the Engine Dynamometer Bench, *Combustion Engines*, nr 50(3), ss. 1–7, 2011
35. Madej H: Internal combustion engine vibration based fault detection using wavelet packet transform, *Diagnostyka*, nr 2 (50):73–8, 2009
36. Payri F, Luján JM, Martín J, Abbad A: Digital signal processing of in-cylinder pressure for combustion diagnosis of internal combustion engines, *Mechanical Systems and Signal Processing*, vol. 24, nr 6, ss. 1767-1784, 2010
37. Narayan S, Grujić I, Stojanović N, Muhammad Usman K, Shitu A, Mahroogi F: Application of Various Signal Processing Methods in Combustion Engines. *Mobility and Vehicle Mechanics*, nr 44(1), ss. 1–12, 2018
38. Pawletko R: Analysing applicability of selected methods to smooth indicator diagrams of marine medium-speed engine. *Polish Maritime Research*, nr 22(2), ss. 55–61, 2015
39. Kim KS, Szedlmayer MT, Kruger KM, Kweon C-BM: Optimization of In-Cylinder Pressure Filter for Engine Research, *US Army Research Laboratory*, 2017
40. Payri F, Olmeda P, Guardiola C, Martín J. Adaptive determination of cut-off frequencies for filtering the in-cylinder pressure in Diesel engines combustion analysis, *Applied Thermal Engineering*, nr 31, ss 14–15, 2011
41. Strona domowa programu Matlab www.mathworks.com/products/matlab, data dostępu 1.06.2019
42. Strona domowa programu R Studio: www.rstudio.com, data dostępu 1.06.2019
43. Strona domowa Python <https://www.python.org/>, data dostępu 1.06.2019
44. Kropiwnicki J. Model of the reciprocating engine using iterative procedures of the transient torque calculation, *Journal of Kones Powertrains and Transport*, vol 17, nr 2, 2010
45. R Core Team: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>, 2018
46. Hyndman R, Athanasopoulos G: *Forecasting: principles and practice*, 2012
47. Abraham. Savitzky, M. J. E. Golay: Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry*, vol 36 (8), ss. 1627-1639, 1964
48. Press WH, Teukolsky SA, Vetterling WT, Flannery BP: *Numerical Recipes In C: The Art Of Scientific Computing*. Cambridge University Press, ss. 650-655, 1992
49. Hyndman RJ, Khandakar Y: Automatic time series forecasting: the forecast package for R, *Journal of Statistical Software*, nr 26(3), ss. 1-22, 2008
50. Hyndman R, Athanasopoulos G, Bergmeir C, Caceres G, Chhay L, O'Hara-Wild M, Petropoulos F, Razbash S, Wang E, Yasmien F: *Forecasting functions for time series and linear models_*. R package version 8.4, 2018
51. Signal Developers: *signal: Signal processing*. URL: <http://r-forge.r-project.org/projects/signal/>, 2013

52. Kropiwnicki J: Model układu silnik-pojazd z wykorzystaniem charakterystyk statycznych silnika. Rozprawa doktorska, Politechnika Gdańska, 2001
53. Kropiwnicki J: Modelowanie układów napędowych pojazdów z silnikami spalinowymi, Gdańsk 2016
54. Kropiwnicki J: The application of spline function for approximation of engine characteristics, *Archiwum Motoryzacji*, (4):235–42, 2000
55. Kropiwnicki J: The Possibilities Of Using Of The Engine Multidimensional Characteristic In Fuel Consumption Prediction, *Journal of Kones Internal Combustion Engines*, (1-2):127–34, 2002
56. Romaniszyn KM, Wnęk H: The approximated dynamic vehicle characteristics constructed based on the driving tests. *Combustion Engines*, nr 3, ss. 38–44, 2011
57. Romaniszyn KM: Ocena różnic w określaniu zużycia paliwa samochodu na podstawie charakterystyki uniwersalnej i dynamicznej, *Silniki Spalinowe*, nr 2, ss. 48–54, 2004
58. Breiman, L: Statistical modeling: The two cultures, *Statistical Science*, 16(3):199–231, 2001
59. Clark M: An Introduction to Machine Learning with Application in R, Center for Social Research, University of Norte Dame, 2013
60. Domingos P: A few useful things to know about machine learning, *Commun ACM*, 55(10):78, 2012
61. Manyika J, Chui M, Brown B, Bughin J, Dobbs R, Roxburgh C, Byers A: Big data: The next frontier for innovation, competition, and productivity, Technical report, McKinsey Global Institute, 2011
62. Hastie, Tibshirani and Friedman: *The Elements of Statistical Learning* (2nd edition), Springer-Verlag, 2009
63. Murphy KP: *Machine Learning: A Probabilistic Perspective*, Massachusetts Institute of Technology, 2012
64. James, G, Witten, D, Hastie, T, Tibshirani, R: *An Introduction to Statistical Learning with Applications in R*, Springer Science+Business Media, New York, 2013
65. Lantz B: *Machine Learning with R*, Second Edition, Packt Publishing, 2015
66. Toomey D: *R for Data Science*, Packt Publishing, 2014
67. Viswanathan V, Viswanathan S: *R Data Analysis Cookbook*, Packt Publishing, 2015
68. Wickham H: *ggplot2, Elegant graphics for data analysis*, Springer, 2009
69. Chang W: *R Graphics Cookbook*, O'Reilly Media, 2012
70. Kohavi R: A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. In: *Proceedings of the fourteenth international joint conference on artificial intelligence*, ss. 1137–43, 1995
71. James GM: Variance and bias for general loss functions, *Machine Learning*, 51:115, 2003
72. Hulten G, Domingos P: Mining complex models from arbitrarily large databases in constant time, *Proceedings of the Eighth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ss. 525–531, Edmonton, Canada, 2002
73. Domingos P: The role of Occam's razor in knowledge discovery, *Data Mining and Knowledge Discovery*, nr 3, ss. 409–425, 1999
74. Cichy M, Makowski S: Modele typu "czarna skrzynka" elektrycznych elementów napędu hybrydowego, *Przegląd Elektrotechniczny*, nr 82(4):16–9, 2006
75. Cichy M, Makowski S: Modelowanie systemów energetycznych z silnikami spalinowymi za pomocą grafów wiązań i równań stanu, *Archiwum Motoryzacji* 1-2, ss. 3-19, 1999
76. Kormański H (promotor: Cichy M.): Zastosowanie Metod modelowania cyfrowego i optymalizacji statycznej do doboru przełożeń stopniowej skrzyni biegów, *Rozprawa doktorska*, Politechnika Gdańska, 1986
77. Rudzińska-Kormańska K (promotor: Cichy M.): Numeryczne metody wyznaczania optymalnego sterowania samochodem, *Rozprawa doktorska*, Politechnika Gdańska, 1989
78. Arsie I, et al.: Models for the Prediction of Performance and Emissions in a Spark Ignition Engine - A Sequentially Structured Approach, *SAE Papers* 980779, 1998

79. Białek P: Badanie wpływu warunków pracy agregatu rolniczego na jego ogólny bilans energetyczny, Rozprawa doktorska, Politechnika Poznańska, 1996
80. Nita J, Schubring T: Zastosowanie funkcji sklepanych w modelowaniu silnika benzynowego dla syntezy jego sterowania. *Journal of KONES*, Warszawa-Gdańsk, ss. 145-151, 1998
81. El-Sayed M, Song D: Automotive Performance Optimization, SAE Papers 980825, 1998
82. Petersen MR, Starkey JM: Nonlinear Vehicle Performance Simulation with Test Correlation and Sensitivity Analysis, SAE Papers 960521, 1996
83. Heath RPG., Mo CY: A Modular Approach to Powertrain Modeling for the Prediction of Vehicle Performance, Economy and Emissions, SAE Papers 960427, 1996
84. Scaife MW, Charlton SJ, Mobley C: A neural network for fault recognition, SAE Technical Paper No. 930861, 1993
85. Ayeb M, Lichtenthäler D, Winsel T, Theuerkauf HJ: SI engine modeling using neural networks, SAE Technical Paper No. 980790, 1998
86. Lichtenthäler, D, Ayeb, M, Theuerkauf, HJ, Winsel T: Improving real-time SI engine models by integration of neural approximators. SAE Technical Paper No. 1999-01-1164, 1999
87. Isermann R, Sinsel S, Schaffnit J: Modeling and real-time simulation of diesel engines for control design. SAE Technical Paper No. 980796, 1998
88. Hanzevack EL, Long TW, Atkinson CM, Traver ML: Virtual sensors for spark ignition engines using neural networks, *Proceedings of the American Controls Conference*, 1997.
89. Atkinson CM, Long TW, Hanzevack EL: Virtual sensing: a neural network- based intelligent performance and emissions prediction system for on-board diagnostics and engine control, SAE Technical Paper No. 980516, 1998
90. Gamo SO, Ouladsine M, Rachid A: Diesel engine exhaust emissions modelling using artificial neural networks, SAE Technical Paper No. 1999-01-1163, 1999
91. De Nicolao G, Scattolini, R, Siviero, C: Modelling the volumetric efficiency of IC engines: parametric, non-parametric and neural techniques, *Control Engineering Practice*, vol. 4, nr 10, 1996.
92. Lenz U., Schroeder D: Artificial intelligence for combustion engine control. SAE Technical Paper No. 960328, 1996
93. Shayler PJ, Goodman, MS, Ma T: Transient air/fuel ratio control of an S.I. engine using neural networks. SAE Technical Paper No. 960326, 1996
94. Lenz U, Schröder D: Air-fuel ratio control for direct injecting combustion engines using neural networks. SAE Technical Paper No. 981060 1998
95. Asik JR, Peters JM, Meyer GM, Tang, DX: Transient A/F estimation and control using a neural network. SAE Technical Paper No. 970619, 1997
96. Wu ZJ, Lee A: Misfire detection using a dynamic neural network with output feedback. SAE Technical Paper No. 980515, 1998
97. Ortmann S, Rychetsky M, Glesner M, Groppo R, Tubetti, P, Morra, G: Engine knock estimation using neural networks based on a real-world database. SAE Technical Paper No. 980513, 1998
98. Müller R, Hemberger H: Neural adaptive ignition control. SAE Technical Paper No. 981057, 1998
99. Winsel T, Ayeb M, Lichtenthäler D, Theuerkauf HJ: A neural estimator for cylinder pressure and engine torque. SAE Technical Paper No. 1999-01-1165, 1999
100. Traver ML: In-cylinder combustion-based virtual emissions sensing, Ph.D. Thesis, West Virginia University, Morgantown, WV, 1999
101. Ludwig C, Ayoubi, M: Fault detection schemes for a diesel engine turbocharger. In *Proceedings of the American Control Conference*, June, 1995
102. Nelson II SA, Filipi ZS, Assanis DN: The use of neural nets for matching compressors with diesel engines, ASME-ICE Spring Technical Conference, ICE-Vol. 26- 3, 1996

103. Kökkülünk G, Akdoğan E, Ayhan V: Prediction of emissions and exhaust temperature for direct injection diesel engine with emulsified fuel using ANN, *Turkish Journal of Electrical Engineering and Computer Sciences*, 21, ss. 2141–2152, 2013
104. Maass B, Stobart R, Deng J: Diesel engine emission prediction using parallel neural networks, *American Control Conference*, ss. 1122–1127, 2009
105. Kiani MKD, Ghobadian B, Tavakoli T, Nikbakht AM, Najafi G: Application of artificial neural networks for the prediction of performance and exhaust emissions in SI engine using ethanol-gasoline blends, *Energy*, vol. 35, s. 65–69, 2010
106. A. Parlak, Y. Islamoglu, H. Yasar, A. Egrisogut, “Application of artificial neural network to predict specific fuel consumption and exhaust temperature for a diesel”
107. Ganapathy T, Gakkhar RP, Murugesan K: Artificial neural network modeling of jatropha oil fueled diesel engine for emission predictions, *Thermal Science*, vol. 13, ss. 91–102, 2009
108. Yusaf TF, Buttsworth DR, Saleh KH, Yousif BF: CNG-diesel engine performance and exhaust emission analysis with the aid of artificial neural network, *Applied Energy*, vol. 87, ss. 1661–1669, 2010
109. Obodeh O, Ajuwa CI: Evaluation of artificial neural network performance in predicting diesel engine NOx emissions, *European Journal of Scientific Research*, Vol. 33, ss. 642–653, 2009
110. Hashemi N, Clark NN: Artificial neural network as a predictive tool for emissions from heavy-duty diesel vehicles in Southern California’, *International Journal of Engine Research*, 8(4), ss. 321–336, 2007
111. Longwic R, Lotko W, Górski K: Modele regresyjne sieci neuronowych w zastosowaniu do identyfikacji przebiegu parametrów procesu spalania w silniku o zapłonie samoczynnym, *Mechanika*, 9(4M), 2012
112. Longwic R et al.: Wykorzystanie metody sieci neuronowych w doborze parametru regulacyjnego układu wtrysku oleju napędowego, *Logistyka*, 3, ss. 3781–3788, 2014
113. Wong KI, Wong PK, Cheung CS, Vong CM: Modeling and optimization of biodiesel engine performance using advanced machine learning methods, *Energy*, 55(x):519–28, 2013
114. Wong KI, Wong PK, Cheung CS, Vong CM: Modelling of diesel engine performance using advanced machine learning methods under scarce and exponential data set, *Applied Soft Computing*, 13(11):4428–41, 2013
115. Mohd Noor CW, Mamat R, Najafi G, Mat Yasin MH, Ihsan CK, Noor MM: Prediction of marine diesel engine performance by using artificial neural network model, *Journal of Mechanical Engineering and Sciences*, 10(1), ss. 1917–1930, 2016
116. Mohd Noor CW, Mamat R, Najafi G, Wan Nik WB, Fadhil M: Application of artificial neural network for prediction of marine diesel engine performance, *IOP Conference Series: Materials Science and Engineering*, 100(1), 2015
117. Wan C, Noor M, Mamat R, Ahmed A: Comparative study of artificial neural network and mathematical model on marine diesel engine performance prediction, *International Journal of Innovative Computing*, 2018
118. Tosun E, Aydin K, Bilgili M: Comparison of linear regression and artificial neural network model of a diesel engine fueled with biodiesel-alcohol mixtures, *Alexandria Engineering Journal*, 55, ss. 3081–3089, 2016
119. Cho Y, Huber T, Lauff U, Reddy R: Optimisation of Gasoline Engines Automation and Machine Learning Techniques in Calibration, *ATZelektronik worldwide*, nr 3, ss. 48–57, 2017
120. Rasmussen CE, Williams CKI: Gaussian processes for machine learning, *International journal of neural systems*, 2004
121. Zeng W, Miwa T, Morikawa T: Exploring Trip Fuel Consumption by Machine Learning from GPS and CAN Bus Data, *Journal of the Eastern Asia Society for Transportation Studies*, nr 11, 2015
122. Wickramanayake S, Bandara HMND: Fuel consumption prediction of fleet vehicles using Machine Learning: A comparative study, 2016 Moratuwa Engineering Research Conference (MERCon), ss. 90–5, 2016

123. Wang S, Ji B, Zhao J, Liu W, Xu T: Predicting ship fuel consumption based on LASSO regression, *Transportation Research Part D: Transport and Environment*, Elsevier, nr 65, ss. 817-824, 2017
124. Wang L, Duran A, Gonder J, Kelly K: Modeling Heavy/Medium-Duty Fuel Consumption Based on Drive Cycle Properties, *SAE Technical Paper 2015-01-2812*, 2015
125. Thompson, GJ, Atkinson CM, Clark NN, Long TW, Hanzevack E: Neural network modelling of the emissions and performance of a heavy-duty diesel engine', *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 214(2), ss. 111-126, 2000
126. Siami-Irdemoosa E, Dindarloo SR: Prediction of fuel consumption of mining dump trucks: A neural networks approach, *Applied Energy*, 151, ss. 77-84, 2015
127. Petersen JP, Jacobsen DJ, Winther O: Statistical modelling for ship propulsion efficiency, *Journal of Marine Science and Technology*, nr 17, ss. 30-39, 2012
128. Perrotta, F, Parry T, Neves LC: Application of Machine Learning for Fuel Consumption Modelling of Trucks, *IEEE International Conference on Big Data*, 2017
129. Çapraz AG, Özel P, Şevkli M, Beyca ÖF: Fuel Consumption Models Applied to Automobiles Using Real-time Data: A Comparison of Statistical Models, *Procedia Computer Science*, nr 83, ss. 774-781, 2016
130. K. Gurney, *An Introduction to Neural Networks*, Routledge, New York, NY, USA, 1997.
131. Haykin S: *Neural Networks: A Comprehensive Foundation*, Prentice Hall, Upper Saddle River, NJ, USA, 1999
132. Fritsch S, Guenther F, Wright MN: neuralnet: Training of Neural Networks. R package version 1.44.2, 2019
133. PN-ISO 15550:2009 - Silniki spalinowe tłokowe -- Określanie i metoda pomiaru mocy silnika -- Wymagania ogólne
134. Mahto A: splitstackshape: Stack and Reshape Datasets After Splitting Concatenated Values. R package version 1.4.6. <https://CRAN.R-project.org/package=splitstackshape>, 2018
135. Dz.U. z 2014 r, poz. 1517, ROZPORZĄDZENIE MINISTRA GOSPODARKI z dnia 21 października 2014 r. w sprawie wartości opałowej poszczególnych biokomponentów i paliw ciekłych
136. Martyr AJ, Plint AM: *Engine Testing: The Design, Building, Modification and Use of Powertrain Test Facilities*, Elsevier, 2012
137. Strona producenta hamowni podwoziowych AVL www.avl.co, data dostępu 1.06.2019
138. Kegl B, Kegl M, Pehan S: Green Diesel Engines, Biodiesel Usage in Diesel Engines, *Lecture Notes in Energy*, nr 12, ss. 5-51, 2013
139. Bździuch D: Pomiar parametrów pracy silnika i badania diagnostyczne pojazdów samochodowych na hamowni podwoziowej VT-2, *Eksplatacja i testy*, 560-8, 2017
140. Kolator B, Janulin M: Wyznaczanie stanów trakcyjnych pojazdu za pomocą hamowni podwoziowej LPS, *Studies and Proceedings of Polish Association for Knowledge Management*, nr 68, 2014
141. Kołodziej E, Skrzyniowski A: Badania diagnostyczne samochodów na hamowni podwoziowej autodyn 30, *Czasopismo Techniczne Mechanika*, nr 109, ss. 129-141, 2012
142. Jaworski A, Kuszewski H, Ustrzycki A: Wyznaczanie współczynników symulacji oporów ruchu w badaniach na hamowni podwoziowej, *Logistyka - Nauka*, nr 4, 2015
143. Europejska Komisja Gospodarcza Organizacji Narodów Zjednoczonych: Regulamin nr 83 Europejskiej Komisji Gospodarczej Organizacji Narodów Zjednoczonych (EKG ONZ) - Jednolite przepisy dotyczące homologacji pojazdów w zakresie emisji zanieczyszczeń w zależności od paliwa zasilającego silnik. Suplement nr 1 do serii poprawek 06, 2011. *Dziennik Urzędowy Unii Europejskiej*. Tom 55, 2012
144. Bielaczyc P, Szczotka A, Woodburn J: Identyfikacja możliwych źródeł błędów i czynników wpływających na wielkość emisji związków szkodliwych spalin, związanych z metodyką przeprowadzania pomiarów emisji na hamowni podwoziowej, *Autobusy, Technika i Eksploatacja*, nr 12:138-43, 2015

145. Bielaczyc P, Szczotka A, Pajdowski P, Woodburn J: Development of vehicle exhaust emission testing methods – BOSMAL’s new emission testing laboratory, *Combustion Engines*, nr 1, ss. 3–12, 2011
146. Strona producenta hamowni podwoziowych Onosokki www.onosokki.co.jp, data dostępu 1.06.2019
147. Al-Lwayzy SH, Yusaf T, Jensen T: Evaluating tractor performance and exhaust gas emissions using biodiesel from cotton seed oil, *IOP Conference Series: Materials Science and Engineering*, nr 36, 2012
148. Roeber JBW, Pitla SK, Hoy RM, Luck JD, Kocher MF: Tractor power take-off torque measurement and data acquisition system, *Biological System Engineering Papers and Publications*, nr 511, 2017
149. Younis SM, Bahnasy AF, Elashry ESR, Elsybaee IM: Development a local system for measuring tractors performance, *Misr J Agric Eng*, 271:34–53, 2010
150. Bietresato M, Mazzetto F: Ideation, realization and experimentation of prototype device for measuring farm tractor fuel consumption during dyno tests, *Engineering for Rural Development*, Jelgava, 2018
151. www.dynamometer-world.com, data dostępu 1.06.2019
152. ag.awdynamometer.com, data dostępu 1.06.2019
153. Strona producenta pomp hydraulicznych Leduc www.hydroleduc.com, data dostępu 1.06.2019

Wykaz rysunków

Rys. 1.1. Pole pracy silnika: $L_s = L_{s1} + L_{s2}$ (kolorem szarym zaznaczono część pola pracy silnika, gdzie jest on wykorzystywany jako hamulec: L_{s2}) [5].	13
Rys. 2.1. Przystawka odbioru mocy zależna od sprzęgła montowana z boku lub z tyłu skrzyni biegów [6].	18
Rys. 2.2. Przystawka zależna od sprzęgła montowana z tyłu skrzyni: 1-silnik, 2-skrzynia biegów, 3-główny wał, 4-pompa hydr., 5-przystawka [7].	18
Rys. 2.3. Przystawka odsilnikowa w pojeździe MAN [7].	19
Rys. 2.4. Przystawki odsilnikowe w pojazdach Mercedes-Benz. a) silnik OM936, maks. moment przystawki 650 Nm b) silnik OM470, maks. moment przystawki 600 Nm [8].	19
Rys. 2.5. Zabudowa śmieciarki w przekroju [11].	22
Rys. 2.6. Schemat działania mechanizmu zagęszczającego odpady [12].	22
Rys. 2.7. Cykl pracy mechanizmu prasującego realizowany przy użyciu 2 par siłowników hydraulicznych [10].	24
Rys. 2.8. Przystawka odbioru mocy (1) z pompą (2) montowaną poprzez wał homokinetyczny (3), sprzęgło elektromagnetyczne (4) oraz tłumik drgań (5).	26
Rys. 3.1. Schemat i oznaczenia modelu GW systemu energetycznego do określania sprawności. (e - uogólniony potencjał, f - uogólniony przepływ, p - uogólniony pęd, q - uogólnione przemieszczenie) [5].	28
Rys. 3.2. Schemat blokowy przepływu energii w pojeździe użytkowym.	29
Rys. 3.3. Uproszczony model układu napędowego pojazdu użytkowego z jednym elementem wykonawczym.	30
Rys. 3.4. Model układu napędowego śmieciarki (opis w tekście).	32
Rys. 5.1. Schemat sieci komunikacyjnej w pojeździe Mercedes-Benz (opis w tekście) [8].	38
Rys. 5.2. Instrukcja przeliczenia wartości parametrów silnika dla ID F004.	41
Rys. 5.3. Algorytm obliczenia parametrów pracy pojazdu na przykładzie wiersza nr 7 z Tabeli 5.	41
Rys. 5.4. Model układu napędowego w formie GW. Silnik spalinowy podzielony na 3 przetworniki strumienia energii (opis w tekście).	43
Rys. 5.5. Moment obrotowy MECU podczas pracy silnika bez obciążenia zewnętrznego dla prędkości obrotowej 600 – 1150 obr/min.	43
Rys. 5.6. Moment obrotowy M_{FMS} podczas pracy silnika z włączonym i wyłączonym odbiornikiem energii elektrycznej o mocy 1,92 kW.	44
Rys. 6.1. Odstęp czasowy pomiędzy rejestrowanym sygnałem ramki FEF2 oraz krok czasowy po interpolacji.	48
Rys. 6.2. Sygnał masowego strumienia paliwa Ge przed i po interpolacji.	48
Rys. 6.3. Odstęp czasowy pomiędzy rejestrowanym sygnałem ramki F004 (zawierającej wartości prędkości obrotowej i momentu) przed i po interpolacji.	50

Rys. 6.4. Przebieg momentu obrotowego przed i po wygładzeniu filtrem S-G oraz średnią ruchomą. Szerokość okna 5.	50
Rys. 6.5. Przebieg momentu obrotowego przed i po wygładzeniu filtrem S-G oraz średnią ruchomą. Szerokość okna 15.	51
Rys. 6.6. Przebieg prędkości obrotowej przed i po wygładzeniu filtrem S-G oraz średnią ruchomą. Szerokość okna 5.	51
Rys. 7.1. Przebieg budowy modelu ML [65].	58
Rys. 7.2. Walidacja krzyżowa 5-krotna. Losowy podział obserwacji na 5 podzbiorów. W każdej iteracji inny podzbiór jest traktowany jako dane walidacyjne. Wynikiem jest wartości uśrednioną ze wszystkich iteracji.	59
Rys. 7.3. Underfitting oraz overfitting na przykładzie dopasowania funkcją wielomianową stopnia n [71].	60
Rys. 7.4. Błąd predykcji na danych treningowych (linia niebieska) i danych walidacyjnych (czerwona) w funkcji stopnia skomplikowania modelu [62].	61
Rys. 7.5. Schemat obliczeniowy prostego neuronu.	70
Rys. 7.6. Struktura sztucznej sieci neuronowej.	72
Rys. 7.7. Punkty pomiarowe z badania silnika w stanie statycznym oraz dopasowana powierzchnia wielomianowa stopnia 3 (wyniki badań własnych).	74
Rys. 7.8. Dane treningowe (czarne), testowe (czerwone), obserwacja x_i (żółty) oraz funkcja y w postaci powierzchni wielomianowej 3go stopnia (wyniki badań własnych).	76
Rys. 7.9. Wartość G_e zmierzone i przewidywane przez model regresji wielomianowej 3go stopnia dla danych treningowych oraz testowych (wyniki badań własnych).	76
Rys. 7.10. Obserwacja x_i ze zbioru testowego w otoczeniu najbliższych 5 obserwacji zbioru treningowego (wyniki badań własnych).	78
Rys. 7.11. Wartości G_e zmierzone i przewidywane przez model KNN dla danych treningowych i testowych, dla $k = 3$ oraz $k = 5$ (wyniki badań własnych).	79
Rys. 7.12. Sztuczna sieć neuronowa o strukturze 2-3-1 z naniesionymi wagami (wyniki badań własnych).	80
Rys. 7.13. Wartości G_e zmierzone i przewidywane przez model ANN dla danych treningowych i testowych (wyniki badań własnych).	80
Rys. 8.1. Histogram występowania punktów pomiarowych w ciągu 1 dnia pracy śmieciarki (290 tys. obserwacji) (wyniki badań własnych).	85
Rys. 8.2. Kryterium maksymalnej odchyłki (z lewej) oraz maksymalnej pochodnej (z prawej) w przyjętym czasie $T = 2$ s w chwili badania $t_i = 25$ s. Dla KMP czerwona linia ciągła oznacza aproksymowaną funkcję liniową, dopuszczalne nachylenie tej linii reprezentuje zielone pole.	87
Rys. 8.3. Kryterium maksymalnej odchyłki (z lewej) oraz maksymalnej pochodnej (z prawej) w przyjętym czasie $T = 5$ s w chwili badania $t_i = 25$ s. Dla KMP czerwona linia ciągła oznacza aproksymowaną funkcję liniową, dopuszczalne nachylenie tej linii reprezentuje zielone pole.	88

Rys. 8.4. Liczba punktów pomiarowych spełniających kryterium maksymalnej odchyłki (z lewej) oraz maksymalnej pochodnej (z prawej) dla rosnącej długości czasowego przedziału obserwacji T	90
Rys. 9.1. Scania P320 podczas testów weryfikacyjnych. Na ramie podwozia zamontowane zostało stanowisko testowe (patrz Załącznik A).	92
Rys. 9.2. Siatka punktów pomiarowych w stanie statycznym w polu pracy silnika.	94
Rys. 9.3. Punkty pomiarowe z badania stanowiskowego. Silnik w każdym zadanym punkcie pracy pracował przez 20 s. Na wykresie widoczne również fazy przejścia między punktami pracy.	94
Rys. 9.4. Uśrednione wartości z punktów pomiarowych z 5 s stanu statycznego.	94
Rys. 9.5. Powierzchnia wielomianowa 3go stopnia dopasowana do punktów pomiarowych (kolor czerwony).	95
Rys. 9.6. Zależność między wartościami Ge zmierzonymi a przewidywanymi.	96
Rys. 9.7. Porównanie otrzymanych modeli w trzech testach stanowiskowych. Linie reprezentują otrzymane modele regresji na tle punktów pomiarowych. Każdy z wykresów przedstawia zależność $Ge(M)$, dla każdej z zadanych prędkości obrotowych (650-1200).	98
Rys. 9.8. Porównanie obserwacji z testów 2 i 3 z przedziałem predykcji (95%) modelu z testu nr 1.	99
Rys. 9.9. Przebieg zadanego obciążenia oraz prędkości obrotowej w czasie podczas badania silnika w stanie dynamicznym.	100
Rys. 9.10. Rozkład punktów pracy w stanie dynamicznym. Czerwone linie przerywane wskazują zadaną prędkość obrotową silnika.	100
Rys. 9.11. Przebieg parametrów pracy silnika w stanie dynamicznym z zaznaczonym przesunięciem czasowym Δt . Pojazd: Scania P320 z silnikiem 9.3 dm^3 .	101
Rys. 9.12. Przebieg parametrów pracy silnika w stanie dynamicznym z zaznaczonym przesunięciem czasowym Δt . Pojazdy: MAN TGS 28.420 z silnikiem 12.4 dm^3 (wykres górny) oraz MAN TGM 26.340 z silnikiem 10.5 dm^3 (wykres dolny).	101
Rys. 9.13. Zużycie paliwa zarejestrowane w teście silnika w stanie dynamicznym.	103
Rys. 9.14. . Regresja wielomianowa: zależność $RMSE_{\text{trening}}$ i $RMSE_{\text{test}}$ oraz $R_{\text{adj, trening2}}$ i $R_{\text{adj, test2}}$ od $lobs$ oraz stopnia wielomianu. Linia ciągła – wartości średnie dla 30 wyników, zacieniowany obszar – odchylenie standardowe. Linia przerywana dla $lobs = 750$.	105
Rys. 9.15. Powierzchnia wielomianowa (3go stopnia) dla 600 punktów treningowych (punkty niebieskie) i 150 testowych (punkty czerwone), $lobs = 750$.	106
Rys. 9.16. Zależność między wartościami Ge zmierzonymi a przewidywanymi przez regresje wielomianową 3go stopnia (RW) wytrenowaną na 600 obserwacjach, testowaną na 150 obs.	106
Rys. 9.17. KNN: zależność $RMSE_{\text{trening}}$ i $RMSE_{\text{test}}$ oraz $R_{\text{adj, trening2}}$ i $R_{\text{adj, test2}}$ od $lobs$ oraz rodzaju modelu. Linia ciągła – wartości średnie dla 30 wyników, zacieniowany obszar – zakres \pm odchylenia standardowego. Linia przerywana dla $lobs = 750$.	108
Rys. 9.18. Model KNN 2 w formie powierzchni dopasowanej do 600 punktów treningowych – punkty niebieskie. Punkty czerwone - 150 obserwacji testowych. $k_{\text{opt}} = 19$.	109
Rys. 9.19. Wykres skrzynkowy $RMSE$ wykorzystany do doboru k_{opt} dla modelu KNN 4 i $lobs = 750$.	110

Rys. 9.20. Zależność między wartościami G_e zmierzonymi a przewidywanymi przez model KNN 4 wytrenowany na 600, testowany na 150 obserwacjach.	110
Rys. 9.21. RMSE oraz $Radj^2$ w zależności od struktury sieci oraz liczby parametrów wejściowych. Modele wytrenowane na 600, testowane na 150 obserwacjach.	113
Rys. 9.22. RMSE oraz $Radj^2$ w zależności od modelu oraz $lobs$. Linia ciągła – wartości średnie dla 30 wyników, zacieniowany obszar – zakres \pm odchylenia standardowego. Wyniki dla modeli z $N_{neu, ukr} = 5$. Linia przerywana dla $lobs = 750$.	114
Rys. 9.23. RMSE oraz $Radj^2$ w zależności od struktury sieci w ANN 1 (wyniki dla $lobs = 750$) oraz w zależności od $lobs$ (wyniki dla $N_{neu, ukr} = 5$). Linia przerywana dla $lobs = 750$. Uwaga: Oś y w innej skali w stosunku do Rys. 9.21 i Rys. 9.22.	115
Rys. 9.24. Struktura sztucznej sieci neuronowej przyjętej do dalszej weryfikacji metody.	115
Rys. 9.25. Zależność między wartościami G_e zmierzonymi a przewidywanymi przez model ANN 4 wytrenowany na 600, testowany na 150 obserwacjach ($lobs = 750$).	116
Rys. 9.26. Przebieg rzeczywistej mocy odbieranej z silnika w jednym symulowanym cyklu.	116
Rys. 9.27. RMSE oraz $Radj^2$ w zależności od modelu. Dla RW, KNN i ANN: $lobs = 750$ i 30 iteracji.	119
Rys. 9.28. Przebieg G_e rzeczywisty (linie czarne) i przewidywany dla 4 wybranych prędkości n . W ramach wartości $\varepsilon\%$ cykl.	119
Rys. 9.29. $\varepsilon\%$ cykl w zależności od modelu. Dla RW, KNN i ANN: $lobs = 750$ i 30 iteracji.	120
Rys. 10.1. Histogram 290000 obserwacji z pomiarów trakcyjnych w ciągu jednego dnia pracy pojazdu. Kolorem czarnym zaznaczone 3 typowe dla PUOP obszary w polu pracy (opis w tekście).	122
Rys. 10.2. Rozkład gęstości występowania punktów pomiarowych w dziedzinie n oraz M przed i po losowaniu warstwowym.	123
Rys. 10.3. Histogram obserwacji po losowaniu warstwowym (50 obs. z warstwy).	124
Rys. 10.4. Przebieg parametrów pracy silnika w trakcie pomiarów trakcyjnych z widocznymi przesunięciami czasowym Δt .	125
Rys. 10.5. $Radj^2$ oraz RMSE obliczone na podstawie danych z pomiarów trakcyjnych ze zbioru I i II w 50 iteracjach.	126
Rys. 10.6. Przebiegi testowe w polu pracy silnika, wyodrębnione przed treningiem, w celu końcowej weryfikacji modeli.	127
Rys. 10.7. Względny błąd przewidywanego łącznego zużycia paliwa $\varepsilon\%$ dla 5 symulowanych przebiegów.	128
Rys. 10.8. Porównanie przebiegu przewidywanego i rzeczywistego G_e (linia czarna) dla iteracji nr 20. W ramach $\varepsilon\%$. Model trenowany na zbiorze II.	129
Rys. 11.1. Moc odbierana z silnika podczas pracy zabudowy śmieciarki w czterech referencyjnych cyklach roboczych.	131
Rys. 11.2. M rejestrowany z magistrali CAN w zależności od rzeczywistego momentu obrotowego na kole zamachowym.	133
Rys. 11.3. Łączne zużycie paliwa Z w cyklu w zależności od ustawionej prędkości silnika.	135

<i>Rys. 11.4. Sprawność eksploatacyjna układu napędowego w cyklu roboczym.</i>	136
<i>Rys. A.1. Hamownia silnikowa firmy AVL [137].</i>	154
<i>Rys. A.2. Schemat hamowni silnikowej [138].</i>	154
<i>Rys. A.3. Schemat hamowni podwoziowej [136].</i>	155
<i>Rys. A.4. Hamownia podwoziowa AVL 150 kW, średnica rolek = 120 cm [137].</i>	156
<i>Rys. A.5. Hamownia podwoziowa do pojazdów z napędem na 4 koła firmy Onosokki [146].</i>	156
<i>Rys. A.6. Stacjonarna hamownia WOM [151].</i>	156
<i>Rys. A.7. Przenośna hamownia WOM podczas obciążania silnika w ciągniku rolniczym [152].</i>	157
<i>Rys. A.8. Ideowy schemat hydrauliczny stanowiska badawczego (opis w tekście)</i>	162
<i>Rys. A.9. Przyływ oleju dla 3 pomp o różnej wydajności jednostkowej w zależności od prędkości obrotowej. Linia przerywana – wymagane $Q = 131 \text{ l/min}$.</i>	164
<i>Rys. A.10. Maksymalny moment obrotowy generowany na kole zamachowym silnika w czasie pracy pod ciśnieniem 210 bar.</i>	164
<i>Rys. A.11. Maksymalny moment obrotowy na wale pompy w czasie pracy pod ciśnieniem 210 bar.</i>	164
<i>Rys. A.12. Schemat stanowiska badawczego wg metody Grafów Wiązań</i>	167
<i>Rys. A.13. Model 3D stanowiska badawczego (opis w tekście)</i>	168
<i>Rys. A.14. Model 3D stanowiska badawczego zamontowanego na ramie podwozia MAN</i>	169
<i>Rys. A.15. Stanowisko pomiarowe (opis w tekście)</i>	170
<i>Rys. A.16. Podwozie marki MAN podczas testów</i>	170
<i>Rys. A.17. Stanowisko zamontowane do ramy podwozia marki Scania</i>	171
<i>Rys. A.18. Silnik Scania podczas testów. Uniesiona kabina kierowcy w celu lepszego chłodzenia silnika</i>	171

Wykaz tabel

<i>Tabela 1. Przykłady pojazdów użytkowych z wyszczególnionym elementem odbierającym moc z silnika spalinowego oraz elementami wykonawczymi.</i>	16
<i>Tabela 2. Orientacyjne zapotrzebowanie na moc w wybranych pojazdach użytkowych.</i>	21
<i>Tabela 3. Reprezentacja przepływu energii wg GW.</i>	28
<i>Tabela 4. Parametry pracy silnika dostępne poprzez interfejs FMS.</i>	39
<i>Tabela 5. Fragment pliku danych zarejestrowanych za pomocą interfejsu FMS z pojazdu Scania.</i>	40
<i>Tabela 6. Dopuszczalne odchyłki parametrów w badaniach silników w stanach statycznych wg PN-ISO 15550:2009.</i>	83
<i>Tabela 7. Parametry pojazdu na którym przeprowadzono pomiary trakcyjne.</i>	85
<i>Tabela 8. Specyfikacja techniczna testowanego pojazdu.</i>	93
<i>Tabela 9. Warunki podczas przeprowadzania testów silnika w stanie statycznym.</i>	95
<i>Tabela 10. Wskaźniki jakości modelu dla trzech testów w stanie statycznym.</i>	96
<i>Tabela 11. Wskaźniki dokładności regresji wielomianowej 3go stopnia na podstawie pomiarów w stanie dynamicznym. Wartości średnie z 30 iteracji, w nawiasach odchylenie standardowe (sd).</i>	104
<i>Tabela 12. Wyniki dla modeli KNN. W nawiasach podane odchylenie standardowe.</i>	107
<i>Tabela 13. Podsumowanie analizowanych modeli ANN i ich struktury.</i>	112
<i>Tabela 14. Wyniki dla modeli ANN.</i>	112
<i>Tabela 15. Zestawienie weryfikowanych modeli wraz z przyjętymi parametrami.</i>	117
<i>Tabela 16. Wskaźniki dopasowania modeli do danych treningowych dla $l_{obs} = 750$ i 30 iteracji.</i>	117
<i>Tabela 17. Wyniki aplikacji modeli do cykli roboczych z badania weryfikacyjnego. Wartości uśrednione dla 33 cykli. $l_{obs} = 750$ i 30 iteracji. W nawiasach podano odchylenie standardowe.</i>	118
<i>Tabela 18. Parametry modeli trenowanych na danych z pomiarów trakcyjnych.</i>	124
<i>Tabela 19. Wskaźniki dokładności modeli trenowanych na danych z pomiarów trakcyjnych. Wartości średnie z 50 iteracji oraz ich odchylenie standardowe (w nawiasach).</i>	125
<i>Tabela 20. Średni $\epsilon\%$ oraz odchylenie standardowe (w nawiasach) w 50 iteracjach dla pięciu przebiegów i trzech modeli trenowanych na zbiorach I i II.</i>	129
<i>Tabela 21. Szczegóły cykli obciążenia silnika.</i>	132
<i>Tabela 22. Łączne zużycie paliwa w cyklu w zależności od ustawionej prędkości silnika.</i>	134
<i>Tabela 23. Różnice w łącznym zużyciu paliwa w cyklu w porównaniu ze zużyciem dla $n = 800$ obr/min.</i>	135
<i>Tabela 24. Sprawność eksploatacyjna układu napędowego w cyklu roboczym.</i>	136
<i>Tabela 25. Parametry techniczne pompy hydraulicznej Leduc TXV 150</i>	163
<i>Tabela 26. Sygnały wejściowe i wyjściowe w układzie sterowania stanowiska badawczego</i>	168

A. ZAŁĄCZNIK - STANOWISKO BADAWCZE

W rozdziale opisane zostało stanowisko badawcze wykorzystane do przeprowadzenia testów na silnikach spalinowych montowanych w podwoziach pojazdów użytkowych. Testy miały na celu weryfikację proponowanych metod odwzorowania charakterystyk energetycznych. Obok przeglądu rozwiązań stosowanych przy badaniu silników, szczegółowo omówione zostały koncepcja oraz założenia projektowe stanowiska. Następnie opisano układ hydrauliczny, układ sterowania oraz model energetyczny stanowiska według metody Grafów Wiązań. Końcowa część rozdziału przedstawia trójwymiarowy model stanowiska oraz zrealizowany projekt w postaci zdjęć z przeprowadzonych testów na podwoziu pojazdu ciężarowego.

Stanowisko badawcze omówione w tym rozdziale zostało w całości sfinansowane oraz wykonane przez firmę Zoeller Tech Sp. z o.o.. Autor niniejszej rozprawy jest autorem projektu oraz kierownikiem procesu wykonania stanowiska. Autor chciałby w tym miejscu podziękować współpracownikom z Zoeller Tech za nieocenione specjalistyczne wsparcie oraz zaangażowanie.

1.1. Przegląd stosowanych rozwiązań

Stanowiska do badania silników spalinowych, nazywane hamowniami można podzielić na trzy grupy: hamownie silnikowe, podwoziowe, hamownie WOM.

1.1.1. Hamownie silnikowe

Hamownia silnikowa to stanowisko pomiarowe, na którym badany jest silnik wymontowany z pojazdu wraz z osprzętem. Hamownia umożliwia wygenerowanie dowolnego obciążenia silnika oraz bardzo dokładny pomiar prędkości obrotowej i momentu. Moment obrotowy jest mierzony bezpośrednio za wałem korbowym, przez co pozwala wyeliminować z pomiaru wpływ strat powstających w układzie napędowym pojazdu, tj. w skrzyni biegów, przekładni głównej czy mechanizmie różnicowym.


Moment oporowy w hamowni generowany jest przez hamulec połączony z wałem korbowym silnika. Hamulce ze względu na sposób odbierania mocy dzielą się na: hydrauliczne (wodne), elektryczne, magnetyczne, tarciove lub powietrzne. Wymienione typy hamulców różnią się pod względem ceny, bezwładności, zakresem pomiarowym i stopniem skomplikowania. Obecnie w nowoczesnych hamowniach stosowane są hamulce elektryczne, wyposażone w silniki indukcyjne prądu przemiennego. Dzięki zminimalizowanej bezwładności i zdolności do generowania dużego momentu oporowego nadają się do badania silników również w stanach dynamicznych. Ponadto moc odbierana z silnika może być odzyskana i przekazana z powrotem do sieci. Do prostych pomiarów

silnika w stanach ustalonych używane są zwykle tańsze hamownie wyposażone w hamulce wodne [136].

Hamownie silnikowe (Rys. A.1) dzięki wyposażeniu w skomplikowaną aparaturę pomiarową pozwalają na badanie wielu parametrów pracy silnika. Obok wielkości niezbędnych do określenia mocy, stanowisko może rejestrować m.in. temperaturę, ciśnienie i przepływ powietrza w układzie dolotowym, ciśnienie i temperaturę oleju, temperaturę paliwa, ciśnienie wtrysku, ciśnienie indykowane, ciśnienie i temperaturę spalin, emisję związków toksycznych (Rys. A.2).



Rys. A.1. Hamownia silnikowa firmy AVL [137].




Rys. A.2. Schemat hamowni silnikowej [138].

Badanie silnika na hamowni silnikowej jest najbardziej skomplikowanym i najbardziej kosztownym spośród dostępnych rozwiązań.

1.1.2. Hamownie podwoziowe

Pomiar momentu obrotowego silnika na hamowni podwoziowej odbywa się pośrednio poprzez pomiar momentu na kołach pojazdu, z uwzględnieniem oporów ruchu. Koła pojazdu umieszczane są na specjalnych rolkach o stosunkowo dużej średnicy (Rys. A.3, Rys. A.4, Rys. A.5), które odpowiedzialne są za generowanie oporu. W ogólności stosowane są dwa sposoby badań: inercyjny i obciążeniowy. Badanie inercyjne wykorzystuje moment bezwładności rolek podczas rozpędzania, co po odpowiednich przeliczeniach pozwala uzyskać wartość momentu obrotowego i mocy pojazdu. Badanie obciążeniowe polega na sterowaniu oporem rolek podczas obrotu, co pozwala na symulowanie rzeczywistej jazdy pojazdu. W tym wypadku jednak wymagany jest dodatkowo precyzyjny pomiar momentu obrotowego między hamulcem a rolką, podczas gdy w badaniu inercyjnym wystarczy znajomość geometrii i masy rolek. [139,140,141]. Opory ruchu uwzględniane podczas symulacji jazdy pojazdu na hamowni podwoziowej wyznaczane są poprzez pomiary drogowe lub przyjmowane z istniejących tabel [142,143].

Hamownie podwoziowe są szeroko wykorzystywane również od przeprowadzania testów homologacyjnych [144]. Takie hamownie oprócz rolek zdolnych symulować przebieg testu wyposażone są dodatkowo w analizator spalin [145].



Rys. A.3. Schemat hamowni podwoziowej [136].

1.1.1. Hamownie WOM

Hamownie WOM wykorzystują przystawkę odbioru mocy (inaczej nazywaną Wałem Odbioru Mocy (WOM), lub PTO) do generowania obciążenia silnika. Hamownie te mogą być stacjonarne (Rys. A.6) lub przenośne (Rys. A.7), co z oczywistych względów jest wygodniejszym rozwiązaniem w przypadku pojazdów wolnobieżnych. Hamownie WOM są szeroko stosowane przy badaniach silników pojazdów rolniczych [147,148,149,150].

Pod względem sposobu odbioru mocy hamownia WOM jest najbardziej zbliżona do stanowiska badawczego przedstawionego w tym rozdziale. Jednak jej użycie do testów silnika zamontowanego w podwoziu pojazdu ciężarowego byłoby kłopotliwe z uwagi na lokalizację przystawki.



Rys. A.4. Hamownia podwoziowa AVL 150 kW, średnica rolek = 120 cm [137].



Rys. A.5. Hamownia podwoziowa do pojazdów z napędem na 4 koła firmy Onosokki [146].



Rys. A.6. Stacjonarna hamownia WOM [151].



Rys. A.7. Przenośna hamownia WOM podczas obciążania silnika w ciągniku rolniczym [152].

1.2. Koncepcja stanowiska badawczego

Do analizy parametrów pracy silnika zamontowanego w podwoziu, z oczywistych względów niemożliwe jest wykorzystanie hamowni silnikowej. Bardziej realnymi rozwiązaniami opisanymi w poprzednim podrozdziale są hamownia podwoziowa oraz hamownia inercyjna. Użycie hamowni podwoziowej dla pojazdu ciężarowego wymaga przetransportowania podwozia przy użyciu lawety do specjalistycznej jednostki obsługującej tego typu pojazdy. Z perspektywy producenta zabudów pojazdów budowa własnej hamowni podwoziowej jest raczej nieopłacalna. Biorąc pod uwagę powyższe ograniczenia powstała potrzeba zaprojektowania stanowiska badawczego, dedykowanego do odwzorowywania charakterystyki energetycznej silnika spalinowego, zamontowanego w podwoziu z przeznaczeniem na pojazd użytkowy.

Produkcja śmieciarek polega w uproszczeniu na wyprodukowaniu zabudowy pojazdu i zamontowaniu jej na podwoziu dostarczonym do fabryki od producenta samochodów ciężarowych (np. MAN, Scania itd.). Na podobnej zasadzie działają firmy produkujące inne zabudowy użytkowe szerzej opisane w rozdziale 2. Dostarczane do fabryki podwozie jest w pełni sprawnym pojazdem, wyposażonym w niezbędne do jazdy podzespoły. Dodatkowo z uwagi na przewidzianą funkcję pojazdu, silnik spalinowy wyposażony jest zawsze w przystawkę odbioru mocy (patrz rozdział 2). Stwarza to możliwość wykorzystania przystawki do generowania obciążenia silnika podczas postoju pojazdu. Fakt ten został wykorzystany przy projekcie oraz budowie specjalnego stanowiska badawczego wykorzystanego w badaniach silników przedstawionych w niniejszej rozprawie.

Koncepcja stanowiska badawczego wykorzystującego przystawkę odbioru mocy do generowania obciążenia silnika spalinowego pojazdu powstała na podstawie poniższych rozważań.

Maksymalna odbierana moc ograniczona jest zalecaniami producenta podwozia dotyczącymi pracy przystawki. Zdefiniowany najczęściej jest maksymalny moment obrotowy pracy przystawki, który rzadko przekracza 600 Nm . Oznacza to, że nie jest w ten sposób możliwe uzyskanie pełnej charakterystyki silnika. Niemniej jednak charakterystyka z niepełnego zakresu pokrywa pole pracy silnika, w którym pracuje podczas realizacji funkcji zabudowy, wykorzystującej właśnie przystawkę.

Urządzenie odbierające moc z silnika w dokładnie taki sam sposób jak zabudowa użytkowa pojazdu, jest idealnym symulatorem obciążenia silnika rzeczywistą pracą zabudowy. Przy znajomości charakterystyki odbieranej mocy przez zabudowę w rzeczywistym pojeździe, stanowisko badawcze może zostać wykorzystane również do przeprowadzania symulacji cykli roboczych.

Wykorzystanie przystawki pozwala na pominięcie dodatkowych nieokreślonych oporów pochodzących z kół jezdnych i ich układu napędowego, które należałoby uwzględnić podczas analizy obciążenia silnika na hamowniach podwoziowych. Stratami jakie należy uwzględnić przy przepływie energii z silnika są straty mechaniczne w przystawce, charakterystyczne dla przekładni zębatych. Nowoczesne rozwiązania konstrukcyjne pozwalają na założenie sprawności takiego mechanizmu na poziomie 0,99. Analiza stanów dynamicznych silnika wiąże się z generowaniem zmiennego obciążenia i zmiennej prędkości obrotowej. Wykorzystanie przystawki minimalizuje wpływ zmian energii kinetycznej mas wirujących na interpretacje momentu obrotowego. W hamowni podwoziowej zauważalny wpływ wywierałyby obracające się koła pojazdu o stosunkowo dużym momencie bezwładności. W omawianym stanowisku należy uwzględnić jedynie masy wirujące silnika i przystawki, oraz w przypadku przystawki montowanej na bloku skrzyni biegów również masy wirujące w przekładni.

Odbierany strumień mocy ruchu obrotowego przystawki musi być zamieniony w inną formę strumienia energii, a następnie rozproszony do otoczenia. Rozważane formy energii to: strumień energii elektrycznej, cieplnej lub hydraulicznej. Stanowisko może więc być wyposażone odpowiednio w generator energii elektrycznej, hamulec wodny lub układ hydrauliczny. Za najmniej skomplikowaną konstrukcję należy uznać stanowisko z układem hydraulicznym. Przystawka odbioru mocy dostosowana jest do bezpośredniego montażu pompy lub poprzez wał homokinetyczny, a obciążanie w układzie realizowane może być przez proporcjonalne zawory dławiące. Straty energetyczne w zaworach dławiących powodują wzrost temperatury oleju hydraulicznego, którego strumień ciepła

rozpraszany jest do otoczenia przy użyciu chłodnic. Zawory dławiące mogą być starowane elektronicznie, a ich krótki czas przesterowania umożliwia zadawanie szybkozmiennego obciążenia silnika.

Odbiornik mocy powinien być zdolny do pracy z prędkością obrotową równej prędkości przystawki. W przeciwnym razie konieczne jest zastosowanie przekładni.

Informacje o parametrach pracy silnika spalinowego powinny być odczytywane z interfejsu FMS. W przypadku prędkości obrotowej magistrala CAN dostarcza dokładnej informacji o prędkości koła zamachowego, zatem niepotrzebny jest dodatkowy czujnik na stanowisku. Układ pomiarowy zużycia paliwa powszechnie stosowany w stanowiskach badawczych ma zdecydowanie zbyt niską częstotliwość i dokładność zapisu w kontekście analizy szybkich zmian chwilowego masowego strumienia paliwa. Czujnik przepływu paliwa w takim układzie montowany jest między pompą paliwa a pompą wysokiego ciśnienia, więc nie ma możliwości rejestracji szybkich zmian podawanej dawki paliwa do cylindrów. Autorowi dotychczas nie udało się znaleźć czujnika przepływu, który przeznaczony do montażu bezpośrednio przed układem wtryskowym. Do analizy zużycia paliwa należy zatem wykorzystać informację ze sterownika silnika dostępną poprzez interfejs FMS. Informacją ta jest precyzyjna i rejestrowana z zadawalającą częstotliwością. Wartość momentu obrotowego odczytana z interfejsu FMS nie jest wartością rzeczywistego momentu dostępnego na kole zamachowym (patrz rozdział 5). Stanowisko powinno być zatem umożliwiać pomiar momentu obrotowego pośrednio, poprzez pomiary innych parametrów energetycznych lub bezpośrednio za pomocą momentomierza.

Odwzorowanie charakterystyki energetycznej silnika wymaga badań w wielu punktach pola pracy. Dodatkowo analizując stany dynamiczne silnika, stanowisko powinno generować zarówno szybki wzrost jak i spadek obciążenia silnika. Podczas gdy obciążenie zadawane jest przez stanowisko, o prędkości obrotowej silnika decyduje jego sterownik. Zatem układ sterowania stanowiska powinien być połączony ze sterownikiem silnika i kierować prędkością obrotową zgodnie z zadanym przebiegiem prędkości. Do tego celu ponownie wykorzystana może być magistrala CAN, po której wysyłane są komunikaty ze sterownika stanowiska do sterownika silnika, zawierające żądaną prędkość. Takie rozwiązanie jest powszechne w pojazdach użytkowych, gdy podczas pracy zabudowy prędkość obrotowa jest utrzymywana na stałym poziomie. Jej wartość jest ustawiana na etapie produkcji zabudowy pojazdu i wynika z konfiguracji układu napędowego. Ta z kolei determinowana jest przez wymagane parametry pracy układu hydraulicznego. Sterownik zabudowy połączony jest z magistralą CAN pojazdu i w momencie uruchomienia zabudowy wysyła odpowiednie komunikaty do sieci.

Na podstawie powyższych informacji, koncepcja stanowiska badawczego zakładała zastosowanie urządzenia wyposażonego w:

- układ hydrauliczny złożony z pompy hydraulicznej, zaworu proporcjonalnego sterowanego elektronicznie oraz chłodnicy oleju
- układ pomiarowy momentu obrotowego napędu pompy hydraulicznej zawierający momentomierz
- układ sterowania połączony jednocześnie z magistralą CAN pojazdu i z pozostałymi elementami elektronicznymi stanowiska

1.3. Założenia projektowe

Po określeniu możliwości finansowych, wykonawczych i eksploatacyjnych, został wykonany projekt stanowiska badawczego spełniający poniższe założenia.

1.3.1. Wymuszanie stanów pracy

Stanowisko umożliwia wymuszanie stanów pracy silnika o żądanych parametrach poprzez sterowanie prędkością silnika i parametrami pracy układu hydraulicznego. Badanie silnika może odbywać się zarówno w stanie statycznym jak i dynamicznym. Stan statyczny osiągany jest poprzez ustawienie stałej prędkości obrotowej przez sterownik silnika oraz stałej nastawy zaworów proporcjonalnych. Skutkuje to stałym przepływem oraz ciśnieniem w układzie hydraulicznym. Uzyskanie stanu dynamicznego silnika może być w teorii realizowane na trzy sposoby: stała prędkość i zmienny moment, zmienna prędkość i stały moment oraz jednoczesne zmiany prędkości i momentu. Należy w tym miejscu zaznaczyć, że nagłe zmiany obciążenia zawsze skutkują zmianą prędkości obrotowej, jednak sterownik silnika dąży do przywrócenia zadanej wcześniej wartości odpowiednio dostosowując dawkę paliwa. Zmiany prędkości są stosunkowo małe w porównaniu ze zmianami obciążenia podczas badania, zatem na potrzeby badania można uznać przebieg prędkości obrotowej za stały. Wszystkie trzy sposoby uzyskania stanu dynamicznego realizowane są na stanowisku poprzez wysyłania informacji o żądanej prędkości obrotowej silnika do sterownika silnika oraz sterowanie zaworem proporcjonalnym w układzie hydraulicznym. Ich czas reakcji jest wystarczający do symulacji szybkozmiennych stanów dynamicznych.

1.3.2. Maksymalna odbierana moc

Standardowa zabudowa śmieciarki wyposażona jest w układ hydrauliczny wymagający przepływu $120 \text{ dm}^3/\text{min}$. W czasie maksymalnego obciążenia ciśnienie w układzie wynosi 180 bar . Jest to wartość ograniczona na etapie produkcji, jednak konstrukcja układu pozwala na zwiększenie limitu do 230 bar . Zatem maksymalna moc

odbierana z silnika spalinowego przez zabudowę może wynosić 46 kW. Stanowisko badawcze symulujące prace zabudowy powinno umożliwiać odbiór tak wysokiej mocy dla każdej analizowanej prędkości silnika z zakresu 600 – 1200 obr/min. Należy przy tym jednak uwzględnić maksymalny moment pracy przystawki, która jest dedykowana do danego podwozia. Odbierana moc w całości przekształcana jest na strumień ciepła oleju hydraulicznego. Stanowisko wyposażone jest w chłodnice olejowo-powietrzne o wydajności umożliwiającej długotrwałe testy silnika pod wysokim obciążeniem.

1.3.3. Symulacja pracy zabudowy

Na stanowisku badawczym oprócz analizowania poszczególnych stanów pracy i procesów stanu pracy silnika symulowane są również cykle robocze zabudowy. Zarejestrowane przebiegi ciśnienia w układzie hydraulicznym rzeczywistego pojazdu podczas codziennej pracy, przy znajomości wielkości przepływu oleju w układzie pozwalają na uzyskanie przebiegu mocy odbieranej z silnika przez zabudowę. Taki przebieg mocy może zostać odtworzony na stanowisku badawczym, po odpowiednich przeliczeniach uwzględniających prędkość obrotową i parametry układu hydraulicznego stanowiska.

1.3.4. Rejestracja danych

Stanowisko rejestruje parametry pracy silnika oraz układu hydraulicznego z częstotliwością co najmniej 10 Hz. Umożliwia to analizę stanów dynamicznych silnika oraz reakcji silnika na zmiany ciśnienia w układzie hydraulicznym. Układ sterowania połączony jest z magistralą CAN pojazdu, momentomierzem oraz czujnikami w układzie hydraulicznym.


1.3.5. Demontowalna konstrukcja

Konstrukcja stanowiska umożliwia szybki montaż i demontaż na testowanym podwoziu. Podobnie jak zabudowa użytkowa, stanowisko montowane jest na ramie podwozia przy użyciu suwnicy. Podłączenie pompy hydraulicznej do przystawki odbioru mocy również jest standardową procedurą, wykonywaną przy produkcji każdego pojazdu użytkowego.

1.4. Układ hydrauliczny stanowiska

Na Rys. A.8 przedstawiono uproszczony schemat układu hydraulicznego stanowiska. Pompa LS (1) zasila układ utrzymując stały spadek ciśnienia na rozdzielaczu (2). Wielkość przepływu oleju może być dowolnie regulowana poprzez nastawę rozdzielacza (2), niezależnie od n_{sil} czy n_{pompy} . W przypadku przerwy w badaniu, rozdzielacz (2) zamyka się, a pompa przestawia się na zerową wydajność minimalizując

odbiór mocy. Za przekształcenie mocy silnika w strumień ciepła oleju odpowiada proporcjonalny zawór przelewowy (3). Strumień ciepła rozpraszany jest do otoczenia przez chłodnicę olejowo-powietrzną (5) oraz w mniejszym stopniu przez zbiornik oleju (7). Zawór bezpieczeństwa (6) nastawiony został na $p = 210 \text{ bar}$.



Rys. A.8. Ideowy schemat hydrauliczny stanowiska badawczego (opis w tekście)

1.4.1. Pompa hydrauliczna

Zadaniem układu hydraulicznego w stanowisku badawczym jest generowanie obciążenia silnika spalinowego. Połączenie pompy hydraulicznej z przystawką powoduje jej ruch obrotowy i tłoczenie oleju. Wydatek oleju określony jest poprzez pojemność jednostkową pompy q i jej prędkość obrotową ω_p zgodnie ze wzorem:

$$Q = \eta \cdot q \cdot \omega_p \quad (\text{A.1})$$

Gdzie η jest sprawnością pompy. Ciśnienie z jakim pompa tłoczy olej wynika z obciążenia układu, a moc hydrauliczna P_{hydr} z jaką pracuje pompa określona jest iloczynem ciśnienia p i wydatku oleju Q :

$$P_{hydr} = p \cdot Q \quad (\text{A.2})$$

Maksymalne ciśnienie w układzie zależy od nastawy zaworu przelewowego, który otwiera się gdy osiągnięta jest krytyczna wartość. Zawór zabezpiecza cały układ przed przeciążeniem. Maksymalne ciśnienie z jakim pracuje układ ustala się na podstawie maksymalnych ciśnień pracy wszystkich elementów w układzie. Zwykle przyjmowane jest na poziomie 180 – 210 *bar*. W układzie hydraulicznym stanowiska badawczego przyjęto wartość 210 *bar*, która umożliwia wygenerowanie dużego obciążenia silnika jednocześnie nie wyczerpując limitu wytrzymałości elementów układu. Dla 210 *bar* odpowiadający przepływ oleju przy mocy 46 *kW* to około 131 *l/min*. Odpowiednio dobrana pompa powinna zapewnić wymagany wydatek nawet dla niskiej wartości n_{sil} . Na Rys. A.9

przedstawiono wydatki oleju dla trzech pomp o rosnącej wydajności jednostkowej w zależności od n_{sil} [32, 153]. Wydajność jednostkowa definiuje również maksymalny moment obrotowy na wałku pompy $M_{p,max}$ dla przyjętego ciśnienia. Większa pompa naturalnie pracuje z większą mocą, jednak odbierany z silnika moment nie zależy od n_{sil} . Z uwagi na przełożenie przystawki r_{PTO} moment na wałku pompy M_P , moment w przystawce M_{PTO} oraz moment na kole zamachowym silnika M_{Sil} łączy zależność:

$$\eta_{PTO} \cdot M_{Sil} = r_{PTO} \cdot M_{PTO} = r_{PTO} \cdot M_P \quad (\text{A.3})$$


Gdzie η_{PTO} jest sprawnością przystawki odbioru mocy. W zdecydowanej większości produkowanych zabudów r_{PTO} zawiera się w przedziale $1,1 \div 1,3$. Na Rys. A.10 oraz Rys. A.11 przedstawiono odpowiednio $M_{Sil,max}$ oraz $M_{PTO,max}$ przy zastosowaniu różnych pomp hydraulicznych i pracy pod ciśnieniem 210 bar, dla przystawki stosowanej w pojazdach marki Scania o przełożeniu $r_{PTO} = 1,19$. Jako odniesienie na wykresach umieszczona została również linia łącząca punkty o stałej mocy 46 kW. Należy również zwrócić uwagę na ograniczenia dotyczące $M_{PTO,max}$ zgodnie z zaleceniami producentów podwozi. $M_{PTO,max}$ nie przekracza zwykle 600 Nm i stosując nawet największą proponowaną pompę (TXV150) warunek ten jest spełniony.

W układzie hydraulicznym stanowiska zastosowano pompę LS (Load Sensing) o zmiennej wydajności Leduc TXV150. Parametry techniczne pompy przedstawiono w Tabeli 25. Obok dużej wydajności jednostkowej, niezbędnej do generowanej wysokiej mocy pompa posiada możliwość pracy dla obydwu kierunków obrotu. Podwozie pojazdu może być wyposażone w przystawkę obracającą się zgodnie z kierunkiem ruchy wskazówek zegara lub przeciwnie (patrząc od tyłu pojazdu), zatem zastosowanie pompy dwukierunkowej gwarantuje uniwersalność. Pompa typu Load Sensing umożliwia również regulację przepływu w układzie poprzez nastawę rozdzielacza.


Dla przyjętego $p_{max} = 210 \text{ bar}$, $n_{sil,max} = 1200 \frac{\text{obr}}{\text{min}}$ i $r_{PTO,max} = 1,3$ moc maksymalna z jaką może pracować stanowisko badawcze wynosi 82 kW.

Tabela 25. Parametry techniczne pompy hydraulicznej Leduc TXV 150


q	150 cm ³ /obr
p_{max}	310 bar
n_{max}	1750 obr/min
m	29.3 kg
kierunek obrotu	prawy/lewy



Rys. A.9. Przyływ oleju dla 3 pomp o różnej wydajności jednostkowej w zależności od prędkości obrotowej. Linia przerywana – wymagane $Q = 131$ l/min.



Rys. A.10. Maksymalny moment obrotowy generowany na kole zamachowym silnika w czasie pracy pod ciśnieniem 210 bar.



Rys. A.11. Maksymalny moment obrotowy na wale pompy w czasie pracy pod ciśnieniem 210 bar.

1.4.2. Rozproszenie energii cieplnej do otoczenia przez zbiornik i chłodnice

Zasada działania stanowisko pomiarowego opiera się na odbiorze mocy z silnika spalinowego i przekształceniu jej w strumień ciepła oleju hydraulicznego. Energia cieplna

oleju magazynowana jest w zbiorniku olejowym, o wymiarach $700 \times 800 \times 1000 \text{ mm}$ i pojemności 470 dm^3 . Strumień ciepła Φ_c odprowadzany do otoczenia przez ścianki zbiornika wynosi 1.2 kW , obliczony wg wzoru:

$$\Phi_c = k \cdot (T_c - T_{ot}) \cdot A_z \quad (\text{A.4})$$

Gdzie A_z to powierzchnia ścianek zbiornika omywanych przez ciecz. Współczynnik przejmowania ciepła k przyjęto $10 \frac{\text{W}}{\text{m}^2\text{K}}$, a różnica temperatur cieczy i otoczenia $T_c - T_{ot} = 40^\circ\text{C}$.

Stanowisko zostało wyposażone w dwie chłodnice powietrzno-olejowe Parker LDC033 [32] połączone równolegle. Dla $Q = 150 \text{ l/min}$ i $T_c - T_{ot} = 40^\circ\text{C}$ chłodnice umożliwiają odprowadzenie strumienia ciepła o wartości 52 kW . Są to największe tego typu chłodnice napędzane silnikiem prądu stałego i zasilane napięciem 24 V dostępne w ofercie tego producenta.

1.5. Układ sterowania stanowiska

Układ sterowania stanowiska odpowiedzialny jest za sterowanie prędkością silnika spalinowego oraz działaniem elementów układu hydraulicznego. Prędkość obrotowa zadawana jest poprzez przesłanie komunikatu po sieci CAN do sterownika silnika. Reakcja sterownika silnika w postaci zmiany dawki paliwa jest natychmiastowa, przy czym sama zmiana prędkości jest szybsza dla silnika pracującego na wysokich n_{sil} . W układzie hydraulicznym występują trzy elementy wymagające sterowania. Pierwszy z nich to nastawa rozdzielacza proporcjonalnego, który decyduje o wielkości przepływu w układzie. Rozdzielacz jest połączony przewodem hydraulicznym LS z pompą, która utrzymuje stałą różnicę ciśnienia przed i za rozdzielaczem, a jego nastawa określa przesunięcie suwaka wewnątrz bloku. Drugim sterowalnym elementem jest proporcjonalny zawór przelewowy, którego nastawa reguluje ciśnienie w układzie. Trzecim elementem jest chłodnica.

Układ sterowania zarówno wysyła sygnały do poszczególnych elementów sterowalnych stanowiska oraz odbiera sygnały z czujników oraz magistrali CAN. Dane rejestrowane są w formie tabelarycznej z krokiem czasowym około 100 ms . W Tabeli 26 zestawione zostały sygnały wejściowe oraz wyjściowe, z rozróżnieniem na te niezbędne do przeprowadzenia badania silnika spalinowego oraz sygnały pomocnicze, które informują między innymi o tym, czy silnik osiągnął już odpowiednią temperaturę (aby pomiary przeprowadzić na rozgrzanym silniku) lub czy konieczne jest uruchomienie chłodnic (sterowanie pracą chłodnic powinno utrzymywać temperaturę oleju hydraulicznego w założonym przedziale, np. $40 \div 45^\circ\text{C}$).


1.6. Model energetyczny stanowiska według metody Grafów Wiązań

Do opisu systemu energetycznego stanowiska badawczego użyto metody Grafów Wiązań, omówioną w rozdziale 3. Na Rys. A.12 przedstawiono schemat stanowiska wg GW z podziałem na podsystemy oraz zaznaczonymi sygnałami wejściowymi i wyjściowymi. Schemat umożliwia formułowanie równań stanu oraz podsumowuje zasadę działania stanowiska omawianego w tym rozdziale.

Przepływ energii w silniku spalinowym wyposażonym w przystawkę odbioru mocy opisanego wg metody GW przedstawiono w rozdziale 4. Do sterownika silnika poprzez magistralę CAN przesyłany jest z układu sterowania stanowiska sygnał I_n , który definiuje prędkość obrotową z jaką powinien pracować silnik.

W stanowisku badawczym strumień energii wychodzący z PTO trafia do zespołu momentomierza M , który połączony jest z PTO poprzez wał homokinetyczny. Zespół złożony jest z dwóch łożysk samocentrujących oraz momentomierza z czujnikiem tensometrycznym. Straty momentu obrotowego w zespole reprezentowane są przez R_M , przy czym spodziewana sprawność całego zespołu zbliżona jest do 1, toteż w trakcie badań przyjęto $M_{PTO} = M_P$, a R_M jako wartość pomijalną. Następnie strumień energii, określony przez moment obrotowy na wale pompy M_P oraz prędkość kątową pompy ω_{PTO} , przekazywany jest do pompy hydraulicznej zmiennego wydatku PH . Strumień energii hydraulicznej określony jest ciśnieniem za pompą p_p oraz przepływem oleju Q . Straty w pompie uwzględnione są jako R_p . Rozdzielacz ROZ sterowany jest sygnałem I_{roz} i decyduje o wielkości przepływu oleju. Jest połączony z pompą przewodem hydraulicznym LS, dzięki czemu poprzez regulację wydajności jednostkowej pompy utrzymywana jest stała różnica ciśnień przed i za rozdzielaczem ($p_p - p_{roz} = const$). Różnica ustawiana jest mechanicznie na pompie i wynosi zwykle od 20 do 30 bar. Strata strumienia energii wynikająca ze spadku ciśnienia na rozdzielaczu reprezentowana jest na schemacie jako R_{roz} . W rzeczywistości z rozdzielacza do zbiornika odprowadzane są przecieki oleju, jednak różnica w przepływie przed i za rozdzielaczem jest pomijalna. Proporcjonalny zawór przelewowy PZP odpowiedzialny jest za zwiększanie lub zmniejszanie ciśnienia w układzie i sterowany jest sygnałem I_{pzp} . Strumień energii hydraulicznej dostarczony do PZP przekształcany jest poprzez dławienie oleju na strumień ciepła określony przez temperaturę oleju T_o oraz entropię \dot{S}_o . Strumień ciepła w głównej mierze rozpraszany jest do otoczenia (R_{ch}) przy użyciu chłodziw powietrzno-olejowych CH . O włączeniu lub wyłączeniu chłodziw decyduje układ sterowania poprzez sygnał I_{ch} . Pozostała część strumienia ciepła o mniejszej temperaturze $T_{o,z0}$ trafia do zbiornika olejowego ZO . Zbiornik olejowy stanowi magazyn energii cieplnej energii L_{z0} , gdzie część tej energii poprzez ścianki zbiornika rozpraszana jest do otoczenia (R_{z0}).

Strumień energii hydraulicznej wynikający z niezerowego ciśnienia za PZP (opór przepływu w chłodnicy < 5 bar) zostaje rozproszony na drodze do zbiornika oleju (R_{pzp}). Strumień ciepła odprowadzany do otoczenia przez pozostałe elementy układu hydraulicznego oraz straty miejscowe i liniowe pozostałych elementów zostały pominięte ze względu na relatywnie niskie wartości.




Rys. A.12. Schemat stanowiska badawczego wg metody Grafów Wiązań

Tabela 26. Sygnały wejściowe i wyjściowe w układzie sterowania stanowiska badawczego


	Sygnały wejściowe	Sygnały wyjściowe
Niezbędne do badania silnika	n_{sil} - Prędkość obrotowa silnika M_{FMS} - Moment obrotowy FMS M_{PTO} - Moment obrotowy na pompie (sygnał z momentomierza) G_e - Masowy strumień paliwa	I_n - Prędkość obrotowa I_{roz} - Nastawa rozdzielacza I_{pzp} - Nastawa proporcjonalnego zaworu przelewowego
Pomocnicze	$T_{o,zo}$ - Temperatura oleju hydraulicznego T_{sil} - Temperatura oleju silnika p_p - Ciśnienie na pompie p_{roz} - Ciśnienie przed zaworem proporcjonalnym Q - Przepływ oleju T_{cch} - Temperatura cieczy chłodzącej silnika	I_{ch} - Włącz/wyłącz chłodnicę

1.7. Model 3D i zrealizowany projekt stanowiska

Model stanowiska badawczego przedstawione na Rys. A.13 wykonany został w programie do modelowania 3D Siemens NX. Stanowisko montowane jest na belkach ramy podwozia (8) za pomocą śrub, wykorzystując istniejące w belkach otwory. Konstrukcję stanowi stalowa rama (7) o wymiarach zewnętrznych 3250x1400x1370 mm z wyznaczoną przestrzenią na zbiornik oleju (4), chłodnicę (9) oraz dodatkowe elementy które mogą zostać zamontowane na potrzeby przyszłych badań. Zawory hydrauliczne (5) oraz sterownik układu sterowania (6) umieszczone są na pulpicie z boku ramy (przedstawione w uproszczony sposób). Zespół momentomierza i pompy hydraulicznej (3) z jednej strony połączony jest poprzez wał homokinetyczny (2) z silnikiem (1), z drugiej wężami hydraulicznymi z pozostałymi elementami układu hydraulicznego. Model stanowiska zamontowanego na podwoziu marki MAN przedstawiono na Rys. A.14.




Rys. A.13. Model 3D stanowiska badawczego (opis w tekście)



Rys. A.14. Model 3D stanowiska badawczego zamontowanego na ramie podwozia MAN

Na zdjęciu poniżej (Rys. A.15) zaznaczone zostały poszczególne elementy stanowiska: 1 - momentomierz, 2 - pompa hydrauliczna LS, 3 - przepływomierz, 4 - filtr oleju wysokociśnieniowy, 5 - czujnik ciśnienia za pompą, 6 - blok hydrauliczny sześciosekcyjny (rozdzielacz), 7 - zawór otwierający przepływ oleju bezpośrednio do zbiornika, z pominięciem rozdzielacza i zaworów proporcjonalnych; 8 - zawór przelewowy (bezpieczeństwa), 9 - proporcjonalny zawór przelewowy, 10 - czujnik ciśnienia za rozdzielaczem, 11 - puszka układu sterowania, 12 - interfejs użytkownika i sterownik. Zdjęcia gotowego stanowiska zamontowanego na podwoziu pojazdu ciężarowego przedstawiono na Rys. A.16, Rys. A.17 oraz Rys. A.18.



Rys. A.15. Stanowisko pomiarowe (opis w tekście)



Rys. A.16. Podwozie marki MAN podczas testów



Rys. A.17. Stanowisko zamontowane do ramy podwozia marki Scania



Rys. A.18. Silnik Scania podczas testów. Uniesiona kabina kierowcy w celu lepszego chłodzenia silnika