



Politechnika Śląska w Gliwicach
Wydział Mechaniczny Technologiczny
Instytut Podstaw Konstrukcji Maszyn

Rozprawa doktorska

**Metoda optymalizacji energochłonności pojazdu z napędem
hybrydowym z wykorzystaniem zarządzania energią w pojeździe**

mgr inż. Mateusz Tyczka

Promotor:

dr hab. inż. Wojciech Skarka, prof. Pol. Śl.

- Gliwice 2019 -

Spis treści

<u>WYKAZ SKRÓTÓW</u>	<u>5</u>
<u>1 WSTĘP</u>	<u>6</u>
1.1 OPIS PROBLEMU	8
1.2 GENEZA PROBLEMU	9
1.3 CEL ROZPRAWY	10
1.4 TEZA ROZPRAWY	11
1.5 ZAKRES ROZPRAWY	11
<u>2 WYBRANE ZAGADNIENIA OPTIMALIZACJI ZUŻYCIA ENERGII W POJAZDACH HYBRYDOWYCH.....</u>	<u>14</u>
2.1 ARCHITEKTURA HEV	15
2.2 NAJWAŻNIEJSZE KOMPONENTY HEV	18
2.3 SPOSOBY REALIZACJI OPTIMALIZACJI ZUŻYCIA ENERGII W POJEŹDZIE HEV O KONFIGURACJI SZEREGOWEJ TYPU PLUG IN.....	28
2.4 ALGORYTMY WYKORZYSTUJĄCE STEROWANIE PREDYKCYJNE	40
2.5 ROZPOZNAWANIE WZORCÓW JAZDY.....	47
2.6 PROGRAMOWANIE DYNAMICZNE.....	51
<u>3 HIERARCHICZNA METODA ZARZĄDZANIA ENERGIĄ W POJAZDACH HYBRYDOWYCH TYPU PLUG-IN.....</u>	<u>53</u>
<u>4 MODEL SYMULACYJNY</u>	<u>57</u>
4.1 MODEL SYMULACYJNY POJAZDU.....	57
4.2 REALIZACJA ALGORYTMU ROZPOZNAWANIA WZORCÓW JAZDY DPR.....	63
4.3 REALIZACJA ALGORYTMU STEROWANIA PREDYKCYJNEGO MPC.....	64
4.4 REALIZACJA PROGRAMOWANIA DYNAMICZNEGO	64
<u>5 OKREŚLANIE PARAMETRÓW MODELU I BADANIE ICH WPLYWU NA WYNIKI SYMULACJI.....</u>	<u>67</u>
5.1 METODYKA GENEROWANIA WIARYGODNYCH PROFILI PRĘDKOŚCI	67
5.1.1 ZNANE Z LITERATURY SPOSOBY GENEROWANIA SZTUCZNYCH PROFILI PRĘDKOŚCI.....	68
5.1.2 METODA TWORZENIA SZTUCZNYCH PROFILI PRĘDKOŚCI	70
5.2 DOBÓR PARAMETRÓW ALGORYTMU ROZPOZNAWANIA WZORCÓW JAZDY DPR	75
5.3 DOBÓR I BADANIE WPLYWU PARAMETRÓW PROGRAMOWANIA DYNAMICZNEGO	79
5.4 DOBÓR PARAMETRÓW STEROWANIA PREDYKCYJNEGO	84
<u>6 BADANIA WERYFIKACYJNE.....</u>	<u>87</u>

7	<u>PODSUMOWANIE.....</u>	<u>94</u>
7.1	WNIOSKI.....	94
7.2	KIERUNKI DALSZYCH PRAC.....	95
	<u>BIBLIOGRAFIA.....</u>	<u>97</u>
	<u>STRESZCZENIE</u>	<u>104</u>
	<u>SUMMARY.....</u>	<u>105</u>

Wykaz skrótów

EREV - ang. extended-range electric vehicles - pojazdy elektryczne o zwiększonym zasięgu,
PHEV – ang. Plug-in hybrid electric vehicle - pojazdy hybrydowe z możliwością ładowania akumulatorów z sieci,
HEV – ang. hybrid electric vehicle - pojazd hybrydowy,
EV – ang. electric vehicle – pojazd o napędzie elektrycznym,
APU – ang. assistant power unit – pomocniczy układ zasilania,
HESS – ang. hybrid energy storage system – hybrydowy magazyn energii,
SOC – ang. state of charge - stopień naładowania,
DOD - ang. degree of discharge – stopień rozładowania,
SA – ang. simulated annealing – algorytm symulowanego wyżarzania,
GA – ang. genetic algorithm – algorytm genetyczny,
LA – ang. linear programming – programowanie liniowe,
ECMS - ang. equivalent consumption minimization strategy - strategia minimalizacji zużycia zastępczego energii,
MPC – ang. model predictive control – sterowanie predykcyjne,
DPR – ang. driving pattern recognition – rozpoznawanie wzorców jazdy,
ES – ang. extremum-seeking – regulatory poszukujące ekstremum,
SDP – ang. semidefinite programming – programowanie półokreślone,
NN – ang. neural network – sztuczne sieci neuronowe,
ENN – ang. Elman neural network – sztuczne sieci neuronowe Elmana,
SVM – ang. support vector machine – maszyna wektorów nośnych,
RLS – ang. recursive least square - rekurencyjne metody NK,
ITS – ang. intelligent transportation systems – inteligentne systemy transportowe,
V2V - ang. vehicle-to-vehicle – komunikacja pojazdu z pojazdem,
V2I – ang. vehicle-to-infrastructure – komunikacja pojazdu z infrastrukturą,
MLD – ang. mixed logical dynamical system - dynamiczne systemy o mieszanej logice,
HYSDEL – ang. hybrid systems description language – język opisu systemu hybrydowego (jedna z metod),
PWA – ang. piecewise affine model - fragmentaryczny model afiniczny,
CFD – ang. computational fluid dynamics – obliczeniowa mechanika płynów,
LED - ang. light-emitting diode - dioda LED,
DP - ang. dynamic programming – programowanie dynamiczne,
DDP – ang. deterministic dynamic programming – deterministyczne programowanie dynamiczne

1 Wstęp

Uwarunkowania światowego rynku wymuszają ciągłą zmianę projektowanych środków technicznych. Jest to podyktowane zarówno czynnikami ekonomicznymi, jak i troską o środowisko naturalne. Dotyczy to także obszaru transportu. Problem rozwoju transportu jest bezpośrednio związany z zanieczyszczeniem powietrza w miastach oraz emisją dwutlenku węgla do atmosfery. W obszarze tym proponuje się coraz więcej regulacji, zarówno lokalnych, takich jak ograniczenia w ruchu wprowadzane przez poszczególne miasta, jak i na szczeblu państwowym oraz Unii Europejskiej. Jednocześnie wyczerpywanie się paliw kopalnych wymusza coraz silniejszą presję ekonomiczną na znajdowanie nowych rozwiązań w dziedzinie transportu. Zarówno problem emisji dwutlenku węgla i zanieczyszczeń do atmosfery, jak i presja ekonomiczna na rozwiązania alternatywne wobec paliw kopalnych, stają się coraz poważniejszym wyzwaniem [1-3].

W obszarze transportu problemy te związane są, między innymi, z efektywnością wykorzystywania energii w pojeździe oraz zmniejszeniem jego całkowitej energochłonności. Przez zmniejszenie energochłonności rozumie się redukcję ilości energii, którą pojazd pobiera ze swych magazynów energii i pomocniczych źródeł zasilania. Można to osiągnąć poprzez zmniejszenie oporów ruchu pojazdu. Uzyskuje się to poprzez zmniejszenie oporów aerodynamicznych pojazdu oraz oporów toczenia pojazdu. Dalsza redukcja oporów toczenia jest utrudniona ze względu na dojrzałą fazę w rozwoju opon oraz wpływ właściwości opon na bezpieczeństwo pojazdu. Choć prace w tej dziedzinie cały czas są prowadzone, to jednak w ostatnich latach postęp na tym polu jest bardzo niewielki. W dzisiejszych czasach, w celu obniżenia oporów aerodynamicznych powszechnie stosuje się analizę obliczeniowej mechaniki płynów *CFD* (ang. *CFD, Computational Fluid Dynamics*), co pozwoliło na projektowanie karoserii pojazdów o bardziej opływowych kształtach i znaczne zmniejszenie oporów aerodynamicznych pojazdów. Obecnie współczynnik oporu powietrza współczesnych samochodów kształtuje się w granicach 0,25- 0,3. Wydaje się, że dalsze znaczne zmniejszenie energochłonności pojazdu może być trudne do osiągnięcia. Poprawę efektywności wykorzystania energii można osiągnąć na różne sposoby, przy czym zawsze dotyczy ona poprawy sprawności elementów pojazdu. Podstawowym, wykorzystywanym powszechnie działaniem jest wymiana komponentów wykorzystujących energię w pojeździe na nowoczesne, sprawniejsze. Przykładem może być zastosowanie oświetlenia *LED* (ang. *light-emitting diode, LED*), w miejsce tradycyjnych żarówek. Dotyczy to zarówno oświetlenia wewnątrz pojazdu czy podświetlenia elementów deski rozdzielczej, jak i świateł drogowych pojazdu. Podobne zabiegi dotyczą innych elementów pojazdu, jak układy klimatyzacji itd. Są to jednak elementy dodatkowe pojazdu, nie mające decydującego wpływu na efektywność wykorzystania energii w pojeździe. Elementem o największym znaczeniu dla sprawności pojazdu jest jego napęd. Poprawę sprawności napędu można osiągnąć poprzez wymianę mechanicznych elementów przeniesienia napędu na elementy o wyższej sprawności. Choć cały czas trwają prace zmierzające do poprawy sprawności układu przeniesienia napędu, to jednak układy te wspólnie

posiadają bardzo wysoką sprawność, zaś ich rozwój osiągnął dojrzałą fazę. Trudno jest oczekiwać na tym polu znaczącej poprawy, zaś wprowadzane poprawki mają zazwyczaj marginalny charakter. Coraz częściej wykorzystywanym rozwiązaniem jest wymiana jednostek napędowych pojazdów, na przykład, na elektryczne. Należy przy tym pamiętać, że energia elektryczna potrzebna do napędzenia pojazdu z elektryczną jednostką napędową musi zostać uprzednio wytworzona. Z tego powodu analiza sprawności pojazdów elektrycznych i ich wpływu na środowisko nie powinna ograniczać się jedynie do sprawności samego pojazdu, ale także uwzględniać sposób wytwarzania energii dostarczanej do pojazdu, zgodnie z analizą od nośników energii do kół pojazdu (*ang. Well-to-Whell*) [4]. Nie mniej jednak silniki elektryczne cechują się znacznie wyższą sprawnością od silników spalinowych. Właśnie na polu pojazdów z silnikiem elektrycznym, które stale się rozwija, wydaje się możliwe uzyskanie największej poprawy. Niewątpliwą zaletą pojazdów elektrycznych jest fakt, że nie emitują one zanieczyszczeń w miejscu użytkowania, co ma duże znaczenie w warunkach ruchu miejskiego i przyczynia się do poprawy jakości powietrza w miastach. Stanowi to silny impuls do rozwijania alternatywnych źródeł energii w pojazdach. Dodatkowo wykorzystanie silników elektrycznych umożliwia zastosowanie odzysku energii z hamowania, która w tradycyjnych pojazdach jest bezpowrotnie tracona. Rozwiązanie to wpływa znacząco na poprawę bilansu energetycznego pojazdu. Oprócz samochodów elektrycznych (*ang. EV, Electric Vehicle*), można wyróżnić także pojazdy hybrydowe (*ang. HEV, Hybrid Electric Vehicle*), które poza główną elektryczną jednostką napędową, posiadają także dodatkowy silnik, zazwyczaj spalinowy [1-2]. Osobną grupę stanowią pojazdy wykorzystujące ogniwa paliwowe (*ang. Fuel Cell*), które posiadają silnik elektryczny, jednak energia do jego napędzania wytwarzana jest w ogniwie paliwowym, najczęściej poprzez kontrolowaną syntezę wodoru i tlenu [1].

Wśród zalet napędów elektrycznych można wymienić bezemisyjną pracę, niski poziom emitowanego hałasu i wysoką sprawność w porównaniu z silnikami spalinowymi. Ich największą wadą jest problem magazynowania energii. Jest to związane zarówno z masą samych baterii, jak i sposobem oraz czasem ich ładowania [1-2]. Problemy te istnieją od kilkadziesiąt lat, w ostatnim czasie odnotowano jednak znaczący postęp w ich przewyżczeniu. Dobrą odpowiedzią na powyższe problemy wydaje się wykorzystanie pojazdów typu *HEV*, łączących zalety pojazdów z silnikiem spalinowym i elektrycznym. Do szczególnego typu pojazdów *HEV* zaliczane są pojazdy typu Plug-in (*ang. PHEV, Plug-in Hybrid Electric Vehicle*). Są one wyposażone w stosunkowo pojemne baterie, które mogą być ładowane zarówno z zewnętrznego źródła energii, jak i ze źródła energii w pojeździe, najczęściej w postaci generatora i silnika spalinowego. Mogą one pokonać pewien dystans wykorzystując jedynie zasilanie z pokładowych baterii. Innymi sposobami na neutralizowanie wad pojazdów elektrycznych są:

- rozwój układów zasilania, w tym baterii o wyższej pojemności,
- rozwój metod szybkiego ładowania akumulatorów lub stosowania ich szybkiej wymiany w pojeździe,
- **rozwój metod odzyskiwania energii w pojazdach**

- zmniejszanie zapotrzebowania energetycznego pojazdów
- **optymalny sposób wykorzystania energii w pojeździe i rozwój metod zarządzania energią w pojeździe**

W niniejszej pracy skupiono się na problemie optymalnego wykorzystania energii w pojazdach typu *PHEV*.

1.1 Opis problemu

Popularne pojazdy, takie jak samochody osobowe, ciężarówki i autobusy można podzielić ze względu na występujący w nich układ napędowy. Podstawowy podział obejmuje pojazdy: z silnikiem spalinowym- benzynowym i o zapłonie samoczynnym, elektryczne oraz alternatywne o marginalnym znaczeniu. Każda z grup posiada swoje zalety. Kolejną grupą zyskującą stale na znaczeniu, są pojazdy hybrydowe (ang. *HEV*), łączące zalety napędu elektrycznego i spalinowego.

W pojazdach *HEV* występuje kilka napędów lub źródeł zasilania. Zależy to od konfiguracji konkretnego pojazdu. Podstawowy podział *HEV* zależy od funkcji dodatkowego napędu. W konfiguracji równoległej (ang. *Parallel Hybrid Electric Vehicle*) zarówno silnik elektryczny, jak i silnik spalinowy pełnią funkcję napędu pojazdu. Pojazd może w takim przypadku być napędzany zarówno przez każdy z silników z osobna lub też przez oba silniki jednocześnie. Podział mocy następuje mechanicznie poprzez odpowiednie przekładnie. W przypadku konfiguracji szeregowej (ang. *Series Hybrid Electric Vehicle* lub *EREV, Extended-Range Electric Vehicles*) funkcję napędową pełni jedynie silnik elektryczny, natomiast silnik spalinowy wraz z generatorem, ma za zadanie jedynie zwiększyć możliwy zasięg pojazdu poprzez doładowanie baterii [1]. Z taką konfiguracją mamy do czynienia w pojazdach typu *PHEV*, które dodatkowo mogą być ładowane energią elektryczną z sieci.

Zarówno w przypadku pojazdów *HEV* o architekturze szeregowej, jak i równoległej, pojawia się problem optymalizacji mocy zużywanej przez pojazd. Dla pojazdów o konfiguracji szeregowej kluczowe znaczenie mają momenty, w których powinien zostać uruchomiony silnik spalinowy, zaś w przypadku konfiguracji równoległej zasadnicze znaczenie ma podział mocy potrzebnej do napędzania pojazdu między poszczególne silniki. Dodatkowym wyzwaniem jest wykorzystanie odzysku energii poprzez hamowanie z odzyskiem oraz wykorzystywanie w części pojazdów zespołów superkondensatorów [1-2, 6]. W przypadku pojazdu *PHEV*, który posiada baterie superkondensatorów mamy do czynienia z pojazdem hybrydowym o konfiguracji szeregowej, z trzema źródłami zasilania o różnych charakterystykach. Są to kolejno bateria akumulatorów, bateria superkondensatorów oraz pomocniczy układ zasilania, złożony najczęściej z silnika spalinowego oraz generatora. Oczywiście wydaje się konieczność zastosowania algorytmu sterowania, który odpowiadałby za podział mocy potrzebnej do zasilenia pojazdu pomiędzy dostępne źródła energii. Dotyczy to także przypadku podziału mocy pochodzącej z hamowania z odzyskiem energii. W dziedzinie tej powstało bardzo wiele prac [7],

jednak pomimo znaczącego postępu w ostatnich latach, wciąż istnieje na tym polu spora przestrzeń do rozwoju. Istniejące algorytmy mogą być w dalszym ciągu rozwijane, a wpływ ich parametrów na sterowanie pojazdem badany. Istnieje także możliwość tworzenia nowych algorytmów zarządzania energią w pojazdach *HEV*, czy to na bazie już istniejących algorytmów, czy też tworząc zupełnie nową koncepcję.

Stan naładowania akumulatorów a także baterii superkondensatorów podlega podczas jazdy ciągłym, dynamicznym zmianom, często trudnym do przewidzenia. Jednocześnie zapotrzebowanie na moc w pojeździe zmienia się nieustannie. Jest to spowodowane przez różne czynniki, takie jak: pogoda, aktualny ruch na drodze, rodzaj drogi i nawierzchni, ukształtowanie terenu czy sposób prowadzenia pojazdu przez kierowcę. Aby konkretna metoda mogła przynieść rezultaty w postaci zmniejszenia kosztów lub wydłużenia zasięgu pojazdu, musi nadawać się ona do zastosowania w pojeździe podczas jego normalnej eksploatacji. Czyni to zadanie utworzenia odpowiedniego algorytmu zarządzającego energią w pojeździe trudnym do realizacji. Zadanie to jest dodatkowo skomplikowane, ze względu na fakt, że informacje o przyszłej trasie lub warunkach ruchu nie mogą być w pełni znane z wyprzedzeniem. W takim wypadku algorytm zarządzający energią musi adaptować się do nowych warunków występujących na trasie i na bieżąco zmieniać strategię [8].

Ze względu na duże zróżnicowanie w działaniu pojazdów *HEV* oraz możliwość rozwoju zarówno metod możliwych do zastosowania w pojeździe w czasie rzeczywistym, jak i tych, które nie nadają się do takiego zastosowania, ale osiągających dokładniejsze wyniki, zdecydowano o zawężeniu tematyki rozprawy w części dotyczącej propozycji nowego algorytmu. Zakres prac został zawężony do algorytmów możliwych do zastosowania w pojazdach *HEV/PHEV* o konfiguracji szeregowej, w czasie rzeczywistym.

Problem badawczy dotyczy więc aktywnego zarządzania rozdziałem mocy wymaganej do napędzania pojazdu w samochodach *HEV/PHEV* o architekturze szeregowej, przy zmiennych warunkach ruchu oraz niepewności dotyczącej przyszłej trasy i uwarunkowań jazdy.

1.2 Geneza problemu

Autor niniejszej pracy od wielu lat związany jest z działającym przy Politechnice Śląskiej kołem naukowym Modelowania Konstrukcji Maszyn oraz działającym przy nim zespołem Smart Power [9]. Zespół Smart Power zajmuje się budową bolidów na zawody Shell Eco- Marathon, których celem jest budowa pojazdów, które są zdolne do pokonania trasy liczącej około 16 km w czasie około 40 min, przy jak najmniejszym zużyciu energii. Zawody mają zasięg międzynarodowy i bardzo wysoki poziom [10]. Zespół odnosił duże sukcesy, między innymi osiągając II miejsce w Europie w 2016 w kategorii Hydrogen, UrbanConcept. Zespół zbudował 2 bolidy. Jeden całkowicie elektryczny, w kategorii Prototype- *Mushellka* oraz jeden z napędem wykorzystującym ogniwa paliwowe, w kategorii

UrbanConcept- *Hydrogenius*. Działalność w zespole skłoniła autora niniejszej rozprawy do zainteresowania się problemem zmniejszenia energochłonności pojazdów, a następnie już bezpośrednio tematyką zarządzania energią w pojazdach *HEV*.

Problem optymalnego zarządzania energią w pojazdach *HEV* wynika z występowania wielu źródeł zasilania takiego pojazdu oraz z występowania kilku napędów w pojeździe. W celu zwiększenia efektywności zużycia energii w pojeździe, należy opracowywać nowe i udoskonalać istniejące algorytmy zarządzania energią w *HEV*. Przez efektywność zużycia energii rozumie się iloraz całkowitej energii wymaganej do ruchu pojazdu i energii pobranej ze źródeł zasilania. Sama zmiana sposobu sterowania może przyczynić się do zmniejszenia zużycia energii a także obniżenia kosztów eksploatacji pojazdu [8]. Wiele z istniejących algorytmów bazuje na różnego rodzaju metodach optymalizacji, co utrudnia lub uniemożliwia ich zastosowanie w rzeczywistych warunkach normalnej eksploatacji w ruchu drogowym [7-8]. Jest to spowodowane koniecznością znajomości pojazdu, trasy i warunków jazdy przed wyruszeniem pojazdu. O ile pierwsze wymaganie jest możliwe do spełnienia, drugie zaś możliwe do spełnienia w bardzo wielu przypadkach, o tyle trzecie nie może być spełnione z wystarczającą dokładnością. Jest to spowodowane zmiennymi warunkami na trasie, które są niezależne od kierowcy i pojazdu *HEV*, będącego obiektem optymalizacji. Dodatkową przeszkodą w zastosowaniu metod optymalizacji jest, bardzo często, długi czas obliczeń, nie pozwalający na prowadzenie obliczeń na bieżąco, w trakcie jazdy. Innym sposobem jest stosowanie prostych reguł określających moment włączenia lub wyłączenia konkretnego źródła energii. Możliwe jest także stosowanie różnych reguł w zależności od aktualnych warunków jazdy. Niezależnie od stosowanego wariantu, wyniki tego typu algorytmu mocno zależą od doświadczenia projektanta [8]. Odpowiedzią na te problemy wydają się być, rozwijane w ostatnich latach, algorytmy bazujące na predykcji zapotrzebowania na moc pojazdu [7-8]. Rozwój tych algorytmów a także ich integracja z innymi istniejącymi algorytmami może zmniejszyć energochłonność i zmniejszyć koszty eksploatacji coraz częściej stosowanych pojazdów *HEV*.

1.3 Cel rozprawy

Celem niniejszej rozprawy doktorskiej jest opracowanie metody zarządzania energią w samochodach *PHEV* w celu zmniejszenia ich energochłonności. Cel pracy realizowano poprzez zwiększenie wiedzy na temat stosowania algorytmów i metod zarządzania energią w pojeździe *PHEV*. Następnie, w rozprawie podjęto próbę syntezy kilku istniejących algorytmów zarządzania energią w pojeździe *PHEV*, w nowy algorytm, w celu zmniejszenia energochłonności pojazdu. Istotne jest, by nowy algorytm, nadawał się do zastosowania w rzeczywistych warunkach eksploatacji pojazdu.

1.4 Teza rozprawy

Sformułowano następującą tezę rozprawy:

Istnieje możliwość zmniejszenia energochłonności pojazdu *PHEV* oraz kosztów jego eksploatacji poprzez zastosowanie odpowiedniej strategii zarządzania energią w pojeździe.

1.5 Zakres rozprawy

Rozprawa dotyczy zmniejszenia całkowitej energochłonności pojazdu o napędzie hybrydowym. Szczególny nacisk położono na zarządzanie energią w pojeździe hybrydowym. Zadanie realizowano poprzez zrozumienie działania obecnie stosowanych algorytmów zarządzania energią w pojeździe i zaproponowaniu nowej strategii zarządzania energią w pojeździe, będącej syntezą obecnie stosowanych algorytmów. Zadaniem strategii jest optymalne rozdysponowanie energii potrzebnej do napędzania pojazdu, pomiędzy źródła zasilania, w celu minimalizacji energochłonności i kosztów eksploatacji pojazdu. Algorytm powinien pozwalać na działanie w warunkach normalnej eksploatacji pojazdu. Działanie strategii zostało zweryfikowane poprzez porównanie wyników działania zaproponowanej metody i innego powszechnie stosowanego algorytmu. Dodatkowo nową metodę zweryfikowano poprzez przetestowanie zmodyfikowanej metody, co pozwoliło na wyciągnięcie bardziej szczegółowych wniosków.

Rozdział pierwszy obejmuje wstęp do rozprawy. Przedstawiono w nim potrzebę udoskonalania pojazdów z napędami elektrycznymi, w tym potrzebę pracy nad lepszymi algorytmami sterowania pojazdem, w szczególności algorytmami optymalizującymi wykorzystanie energii w pojeździe. Opisano problemy w zastosowaniu znanych algorytmów optymalizacyjnych. Położono szczególny nacisk na eksploatację pojazdu w rzeczywistych warunkach. Następnie przedstawiono genezę problemu zarządzania energią w pojeździe *PHEV*, oraz problemy z aktualnie wykorzystywanymi algorytmami. W szczególności podkreślono potrzebę dalszego udoskonalania istniejących i tworzenia nowych algorytmów zarządzania energią w pojeździe *PHEV*. Następnie opisano cel pracy. Celem pracy jest opracowanie metody zarządzania energią w pojeździe *PHEV*, w celu zmniejszenia jej energochłonności. W rozprawie położono szczególny nacisk na możliwość wykorzystania algorytmu w rzeczywistych warunkach, w jakich pojazd *PHEV* mógłby być eksploatowany. Następnie przedstawiono tezę rozprawy, w której stwierdzono, że odpowiednie zarządzanie mocą w pojeździe może przyczynić się do zmniejszenia energochłonności i kosztów eksploatacji *PHEV*.

W rozdziale drugim opisano wybrane aspekty optymalizacji energii w pojazdach hybrydowych. Na początku opisano architekturę pojazdów *HEV* oraz przedstawiono sposób działania pojazdu dla każdego z typów *HEV*. Następnie opisano budowę napędu pojazdu *HEV* i najczęściej stosowane

podzespoły. W kolejnym, obszernym podrozdziale opisano kluczowe pojęcia wykorzystywane w dalszej pracy, takie jak optymalizacja czy energochłonność. W tym samym podrozdziale przedstawiono także przegląd literatury dotyczący optymalizacji zużycia energii w *PHEV* i *HEV*. Opisano wady i zalety poszczególnych metod. W opisie szczególną wagę przywiązano do możliwości zastosowania algorytmu w warunkach rzeczywistej eksploatacji pojazdu. Dotyczy to zarówno informacji potrzebnych na wejściu algorytmu, by możliwe było jego zastosowanie, jak i złożoności oraz czasochłonności obliczeń. W kolejnych podrozdziałach szerzej opisano metody i algorytmy, które mogą być łatwo wykorzystane w proponowanej metodzie, zarówno ze względu na dostępność danych i narzędzi służących do modelowania, jak i na złożoność obliczeniową umożliwiającą wykonanie wymaganych obliczeń w czasie rzeczywistym. W szczególności skupiono się na algorytmach rozpoznawania wzorców jazdy i algorytmach predykcyjnych, służących do zarządzania energią w pojazdach hybrydowych. Następnie opisano metody optymalizacji, które mogą być zastosowane w ramach algorytmów predykcyjnych wraz z ich wadami i zaletami. Szczególny nacisk położono na często wykorzystywaną w innych pracach metodę programowania dynamicznego.

Trzeci rozdział opisuje nową metodę zarządzania energią w *PHEV*, zaproponowaną przez autora niniejszej rozprawy. Metodę zaproponowano na podstawie innych istniejących algorytmów. Jest ona syntezą kilku algorytmów, opisanych w rozdziale drugim. Opisano jej sposób działania i powody, dla których zdecydowano się na taką formę nowej metody. Następnie nakreślono potencjalne wady i zalety nowej metody, na podstawie wiedzy o algorytmach, które zostały wykorzystane do jej opracowania. Ze względu na różnice w budowie pojazdów *HEV* i tym samym różnice w samych strategiach zarządzania energią w tych pojazdach, zdecydowano się na zawężenie pola działania nowej strategii do pojazdów *HEV* o architekturze szeregowej, typu plug-in (*PHEV*).

Rozdział czwarty jest dokładnym opisem modelu matematycznego pojazdu oraz zastosowanego algorytmu. W pierwszej kolejności opisano model matematyczny samego pojazdu. Modelowanym pojazdem *PHEV* był samochód ciężarowy o masie własnej wraz z ładunkiem równej 16,5t. Wybór został podyktowany przede wszystkim dobrym dostępem do danych na temat pojazdu [11]. Dodatkowym czynnikiem jest fakt, że w przypadku pojazdów wykorzystywanych komercyjnie, oszczędności na kosztach eksploatacji, ze względu na oszczędność energii i paliwa mają o wiele większe znaczenie. Wszystkie dane i parametry, niezbędne do zbudowania opisu matematycznego pojazdu zostały opisane i podane. Sam model matematyczny opisywał *HEV* typu plug-in o konfiguracji szeregowej i składał się z: silnika spalinowego wraz z generatorem (ang. assistant power unit, *APU*), baterii akumulatorów, baterii supekondensatorów oraz konwertera *DC/DC*. Następnie, w kolejnych podrozdziałach szczegółowo opisano zastosowany algorytm zarządzania energią w pojeździe. W pierwszej kolejności opisano zastosowany algorytm rozpoznawania wzorców jazdy. Jest on rozważany jako pierwszy, ze względu na kolejność działania całego algorytmu. Za jego pomocą określone są panujące w danym momencie warunki na trasie. Informacje z niego trafiają następnie do algorytmu predykcji prędkości pojazdu. W zależności od warunków panujących na trasie, uruchamiany jest algorytm predykcji

prędkości pojazdu z odpowiednim, odpowiadającym warunkom na trasie, parametrem. Opis algorytmu predykcyjnego prędkości pojazdu został przedstawiony w kolejnym podrozdziale. Następnie opisano algorytm odpowiedzialny za optymalizację energii w pojeździe dla przewidzianej prędkości pojazdu. W niniejszej rozprawie zdecydowano się na zastosowanie programowania dynamicznego, którego sposób działania został szczegółowo opisany. Na koniec dokładnie opisano przepływ informacji pomiędzy poszczególnymi fragmentami algorytmu oraz uszczegółowiono samą ideę syntezy algorytmów.

Piąty rozdział opisuje badania cząstkowe prowadzone w celu określenia optymalnych parametrów dla poszczególnych elementów modelu. W rozdziale tym opisano także szczegółowo wszystkie parametry wykorzystane w ostatecznie zastosowanym algorytmie. W pierwszej kolejności przystąpiono do określenia danych wejściowych, na których następnie przeprowadzono eksperymenty. W przypadku badanych modeli, danymi tymi były profile prędkości pojazdu bądź też profile zapotrzebowania na energię w pojeździe. Z uwagi na małą liczbę dostępnych profili prędkości, w szczególności dla wybranego typu pojazdu oraz uwzględniającego konkretne sytuacje drogowe, zdecydowano się na utworzenie sztucznych profili prędkości. Metoda tworzenia profili została dokładnie opisana. Przedstawiony sposób postępowania może posłużyć do wygenerowania dowolnie dużej liczby profili prędkości, odzwierciedlającej konkretne warunki drogowe. Możliwe jest także wykorzystanie bliżej przedstawionej metody, do generowania dokładniejszych sztucznych profili prędkości, na podstawie historycznych przejazdów pojazdu na danej trasie. W kolejnych podrozdziałach opisano badania różnych parametrów części składowych zaproponowanej metody. Badania uwzględniały wpływ parametrów na działanie metody w różnych warunkach drogowych. Dla każdego badanego parametru przeprowadzono wiele różnych symulacji, tak aby wyniki nie zależały tylko od konkretnego profilu prędkości pojazdu, lecz by dawały całościowy obraz. Następnie na podstawie badań dobrano optymalne wartości dla każdego z algorytmów. Przy doborze kierowano się dokładnością i czasochłonnością obliczeń.

W szóstym rozdziale opisano ostateczne badanie całego algorytmu. Metoda została przebadana na różnych typach profili prędkości, tak by możliwe było sprawdzenie działania metody w różnych sytuacjach drogowych. Badania zostały przeprowadzone na wielu profilach dla różnych sytuacji drogowych. Pozwoliło to wyeliminować sytuację, w której poszczególne profile rzutowałyby na wyniki i uniemożliwiły wyciągnięcie ogólnych wniosków. W celu porównania wyników uzyskiwanych przez wybraną metodę porównano jej wyniki z wynikami uzyskanymi przez prostą strategię wykorzystującą reguły oraz z modyfikacjami proponowanej metody. Pozwoliło to na wyciągnięcia bardziej szczegółowych wniosków.

Rozdział siódmy poświęcony jest na podsumowanie całej pracy. W pierwszej części nastąpiło krótkie streszczenie pracy wykonanej przez autora niniejszej rozprawy. Następnie autor wyciąga szczegółowe wnioski oraz sygnalizuje kierunki dalszych prac.

2 Wybrane zagadnienia optymalizacji zużycia energii w pojazdach hybrydowych

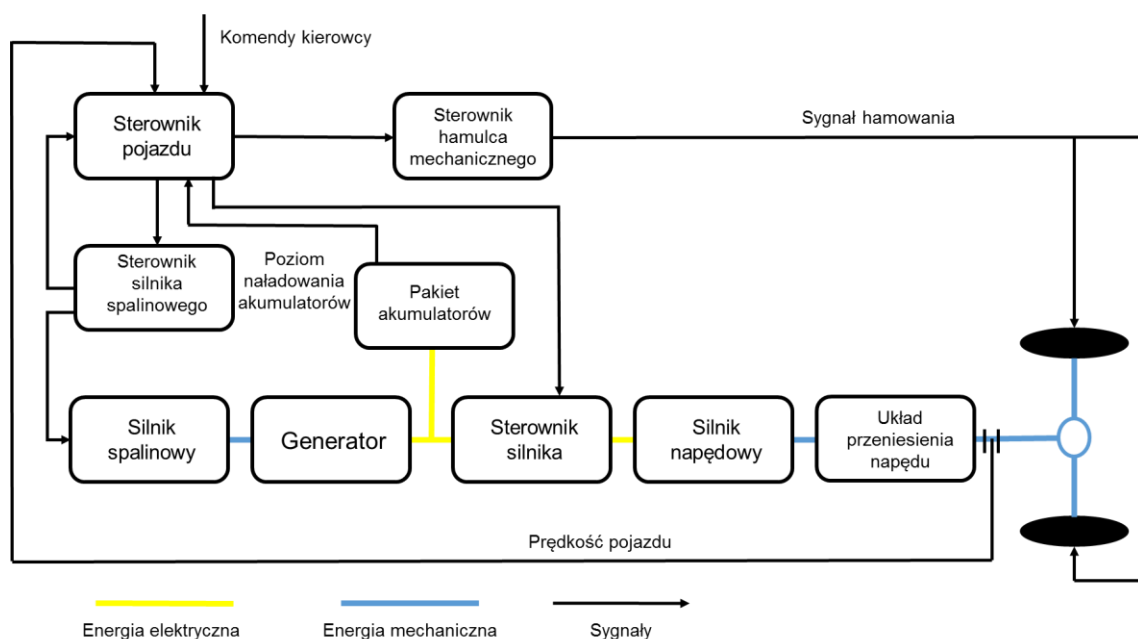
Samochody hybrydowe są powszechnie znane i używane od wielu lat. Pierwszy samochód z napędem hybrydowym powstał już w 1899 r. i został pokazany w Paryżu [1]. Twórcami pojazdu były Liège z Belgii oraz Vendovelli and Priestly Electric Carriage Company z Francji. Pojazd ten posiadał napęd hybrydowy o strukturze równoległej, składający się z małego benzynowego silnika spalinowego oraz silnika elektrycznego, zasilanego z akumulatorów kwasowo- ołowiowych. W czasie normalnej jazdy i jazdy z górki, baterie były ładowane, zaś w trakcie zwiększonego zapotrzebowania na moc, silnik elektryczny dostarczał dodatkowej mocy do napędu pojazdu. Od tego czasu powstały liczne, nowe konstrukcje. Rozwój *HEV* w tamtych latach był związany z słabymi silnikami spalinowymi, napęd elektryczny uzupełniał w tych pojazdach niedobory mocy oraz zwiększał ich zasięg. Po stronie elektrycznej, w pojazdach tych wykorzystywano najprostsze, jedyne dostępne w tamtym czasie, rozwiązania. Dalszy rozkwit pojazdów *HEV* został zatrzymany przez gwałtowny rozwój silników spalinowych po I wojnie światowej. Silniki spalinowe stały się mniejsze i bardziej efektywne, tym samym zniknęła potrzeba ich wspomagania przez silnik elektryczny [1]. Kolejny rozwój samochodów hybrydowych nastąpił po ulepszeniu metod sterowania silnikiem elektrycznym, które nastąpiło wraz z pojawieniem się nowoczesnej elektroniki, w połowie lat 60-tych. W latach 70-tych powstało kilka prototypów *HEV*, żaden jednak nie trafił na rynek. Z powodu kryzysów na rynkach ropy naftowej w roku 1973 i 1977, wysiłki naukowców koncentrowały się wokół EV. Dalszy rozwój skutkowało pojawieniem się kolejnych prototypów, o znacznie większych mocach i osiągających prędkości powyżej 80 mph. Można do nich zaliczyć takie konstrukcje jak: Intrepid ESX-1, 2 i 3, Ford Prodigy, GM Precept. Na europejskim rynku wyróżnić można francuski Renault Next czy Chico marki Volkswagen. Pojazdy te jednak nigdy nie weszły do masowej produkcji. Największy wpływ na rozwój rynku *HEV* miała japońska Toyota Prius, która zadebiutowała na rynku w 1997 roku. Oprócz niej, dostępne dla szerokiego rynku stały się Honda Insight Hybrid oraz Honda Civic Hybrid [1]. Samochody te cechowały się znakomitymi, bardzo niskimi wynikami konsumpcji paliwa w stosunku do pokonanego dystansu. Od tego czasu nastąpił znaczący rozwój *HEV*, stały się one powszechnie stosowane, a ich udział w runku rośnie. Dotyczy to nie tylko rynku samochodów osobowych, ale także samochodów dostawczych i ciężarowych, a także autobusów [11-13].

W związku z rosnącym zainteresowaniem *HEV* ich konstrukcje są ciągle rozwijane. Związane jest to z rozwojem technologicznym oraz coraz większą konkurencją na rynku *HEV*. Wprowadzane zmiany dotyczą zarówno budowy samego pojazdu, sposobu sterowania pojazdem jak i samej koncepcji napędu. Zmiany technologiczne umożliwiają także stosowanie coraz bardziej wyszukanych strategii sterowania i zarządzania energią w pojeździe. W ostatnich latach nastąpił znaczący rozwój w tej dziedzinie [7].

2.1 Architektura HEV

Istotą *HEV* jest posiadanie co najmniej dwóch źródeł napędu, przy czym zazwyczaj jedno ma charakter wspomagający. W przypadku współczesnych *HEV*, pojazd napędzany jest za pomocą silnika spalinowego benzynowego lub o zapłonie samoczynnym oraz silnika elektrycznego. Zadanie to może być realizowane na różne sposoby. W zależności od sposobu działania układu napędowego możemy wyróżnić kilka struktur pojazdu. Dodatkowo w pojeździe *HEV* występuje wiele źródeł energii. Energię potrzebną do napędzenia pojazdu może pochodzić z energii elektrycznej, przekształcanej następnie na energię mechaniczną lub z paliwa, które w silniku spalinowym zamieniane jest na energię mechaniczną. Energia elektryczna w *HEV* może pochodzić z akumulatorów lub rzadziej układu akumulatorów i superkondensatorów. Do ładowania akumulatorów można wykorzystać energię elektryczną pochodzącą z sieci elektrycznej, energię odzyskiwaną w trakcie hamowania z odzyskiem energii lub też pomocnicze źródło zasilania w pojeździe, takie jak silnik spalinowy połączony z generatorem lub ogniwo paliwowe. Powyższe zależności sprawiają, że pojazdy *HEV* mogą istotnie różnić się pod względem sposobu działania i architektury układu napędowego i układu zasilania. Najważniejszy podział architektury *HEV*, z punktu widzenia działania napędu i hybrydyzacji źródeł energii, obejmuje podział na *HEV* szeregowe i równoległe.

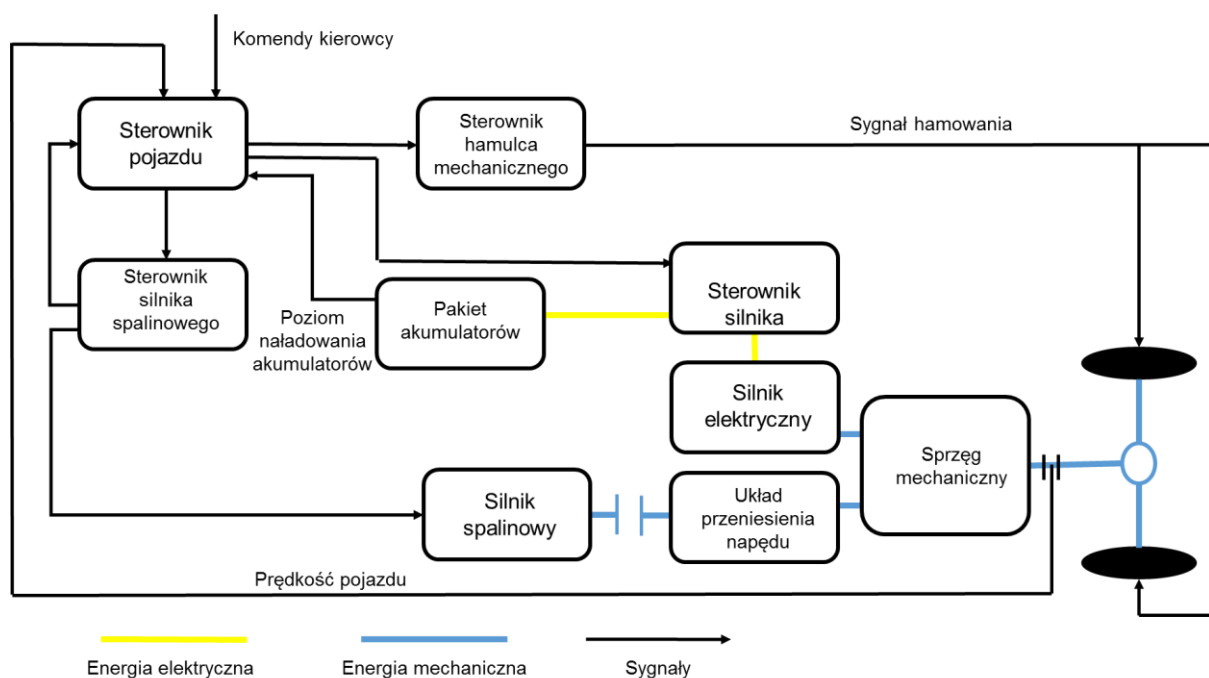
Architektura szeregową w pojazdach *HEV* wywodzi się z pojazdów *EV*. Jak wspomniano wcześniej pojazdy *EV* mają dużo zalet w stosunku do samochodów z silnikiem spalinowym, takich jak wysoka sprawność czy zeroemisyjna praca. Niestety samochody *EV* mają ograniczony zasięg spowodowany niską pojemnością baterii, z racji ich ciężaru i objętości. Dodatkowym problemem jest długi czas ładowania akumulatorów.



Rys. 1 Schemat architektury szeregowej *HEV* [1]

Pierwotnym zamysłem samochodów *HEV* o architekturze szeregowej była możliwość zwiększenia zasięgu pojazdu *EV* poprzez dodanie do pojazdu silnika spalinowego i generatora, w celu doładowania baterii pokładowych [1-2]. Architektura typowego pojazdu *HEV* przedstawiono na rysunku Rys. 1 [1]. Pojazd napędzany jest przez elektryczny silnik napędowy. Energia zasilająca silnik pochodzi z baterii oraz zestawu generatora z silnikiem spalinowym. Generator wraz z silnikiem spalinowym dostarcza dodatkowej mocy w przypadku dużego zapotrzebowania na energię oraz doładowuje baterie w przypadku mniejszego obciążenia silnika napędowego. Sterownik silnika odpowiada za takie sterowanie silnikiem, by ten dostarczył wymaganej mocy napędowej do pojazdu. Sposób doboru parametrów zespołu napędowego, jest w tym przypadku identyczny, jak w przypadku samochodu elektrycznego o podobnych parametrach użytkowych. Jednakże, ze względu na dodatkowe elementy w pojeździe, w postaci dodatkowych źródeł zasilania, sam sposób sterowania tego typu pojazdem musi być inny i obejmować elementy związane z zarządzaniem energią w pojeździe.

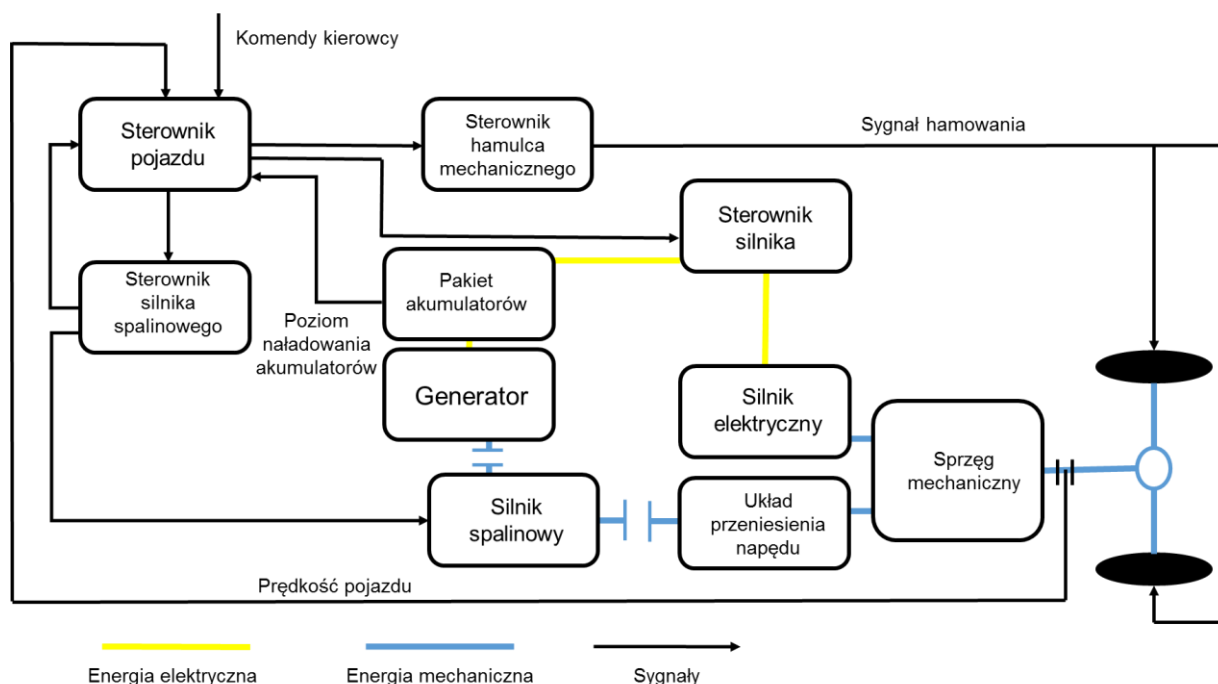
Architektura równoległa pomimo, podobnych komponentów zainstalowanych w pojeździe *HEV*, działa w inny sposób niż architektura szeregową. W przypadku architektury szeregowej funkcję silnika napędowego, w całości, pełni silnik elektryczny. W przypadku architektury równoległej, zarówno silnik elektryczny, jak i silnik spalinowy mogą przekazywać swą moc na koła pojazdu [1]. Podział mocy w tego typu pojeździe odbywa się mechanicznie poprzez system sprzęgieł i przekładni. Podstawową różnicą w tego typu pojeździe jest występowanie sprzęgu mechanicznego oraz brak generatora. Typową architekturą równoległą *HEV* przedstawiono na Rys. 2 [1]. Poszczególne rozwiązania mogą różnić się pod względem lokalizacji układu przeniesienia napędu oraz sposobu rozwiązania sprzęgu mechanicznego.



Rys. 2 Schemat architektury równoległej *HEV* [1]

Największymi zaletami tego typu konfiguracji jest brak generatora oraz brak wielokrotnej konwersji energii mającej miejsce w przypadku *HEV* o konfiguracji szeregowej. W tej ostatniej, w pierw energia mechaniczna konwertowana jest na energię mechaniczną w generatorze, a następnie ponownie konwertowana na energię mechaniczną w silniku napędowym. Ogranicza to możliwość do uzyskania sprawność całego pojazdu. Jednakże ze względu na mechaniczne połączenie pomiędzy silnikami i kołami napędowymi pojazdów sterowanie w przypadku konfiguracji równoległej jest bardziej skomplikowane [1]. Jednocześnie zastosowanie nowoczesnych komponentów elektronicznych i superkondensatorów może znacznie poprawić sprawność pojazdu *HEV* w konfiguracji szeregowej [14].

Architektura szeregowo-równoległa łączy zalety obu wspomnianych powyżej typów architektury. W rozwiązaniu tym silnik spalinowy może zarówno służyć do bezpośredniego napędzania kół napędowych pojazdu, jak i do ładowania baterii pojazdu. Sposób wykorzystania silnika spalinowego w pojeździe zależy od aktualnej strategii sterowania. Realizacja strategii jest możliwa za pomocą układu sprzęgieł. W zależności od zaszprzężenia, moc z silnika spalinowego może być przenoszona do generatora lub na koło pojazdu. Dzięki takiemu rozwiązaniu możliwe jest efektywne wykorzystanie mocy silnika spalinowego w większym stopniu, niż w rozwiązaniu o architekturze szeregowej i równoległej. Wadą rozwiązania jest bardziej rozbudowany układ napędowy oraz większa trudność w realizacji strategii sterowania [15]. Schemat *HEV* o architekturze szeregowo-równoległej został przedstawiony na Rys. 3 [1, 15].



Rys. 3 Schemat architektury równoległej *HEV* [1, 15]

W każdym z wymienionych typów architektury można wyróżnić pojazdy typu plug-in. Pojazdami typu plug-in nazywamy wszystkie pojazdy *EV* i *HEV*, które mogą być ładowane z sieci elektrycznej za pomocą gniazdek lub specjalnych stacji ładowania.

2.2 Najważniejsze komponenty HEV

Pojazdy *HEV*, pod wieloma względami nie różnią się niczym od konwencjonalnych pojazdów z silnikami spalinowymi. Podobieństwa dotyczą w szczególności cech estetycznych i ergonomicznych pojazdów. Elementy takie jak: karoseria, fotele, szyby pojazdu itp. są identyczne lub bardzo zbliżone do analogicznych elementów występujących w konwencjonalnych pojazdach z silnikiem spalinowym. Dotyczy to także takich cech pojazdu jak: wygląd i rozmieszczenie elementów w kabinie kierowcy, sposób otwierania drzwi czy umiejscowienie bagażnika z tyłu pojazdu. Większość wymagań bezpieczeństwa również jest identyczna, a dodatkowe wymagania związane są z zabezpieczeniem pojazdu pod względem elektrycznym, ze względu na duże moce elektryczne. Istotną różnicę w stosunku do pojazdów konwencjonalnych stanowi zespół napędowy pojazdu, wraz z układem magazynowania energii elektrycznej w pojeździe. W podrozdziale tym opisano, po krótko, najważniejsze elementy układu napędowego oraz magazynowania energii w samochodach *HEV*. Można do nich zaliczyć silnik elektryczny służący do napędu pojazdu, baterię akumulatorów, baterię superkondensatorów oraz zespół generatora wraz z silnikiem spalinowym.

Silniki elektryczne służące do napędu pojazdów *EV* i *HEV* muszą być dostosowane do szeregu specyficznych warunków pracy, takich jak: częsty rozruch i zatrzymywanie, duży moment przy małej prędkości obrotowej do pokonywania wzniesień, duża prędkość obrotowa w czasie jazdy z dużą prędkością oraz szeroki zakres parametrów pracy. Inaczej sytuacja wygląda w przypadku silników elektrycznych stosowanych w przemyśle, które najczęściej są dobierane do konkretnych warunków pracy. Ze względu na swoje cechy, silniki montowane w *EV* i *HEV* zasługują na osobną podkategorię [1-2]. Główne różnice pomiędzy silnikami elektrycznymi używanymi w przemyśle i w pojazdach *EV* i *HEV* wyglądają następująco [2]:

- Silniki montowane w *EV* i *HEV* powinny posiadać 4 do 5 razy większy moment maksymalny w stosunku do nominalnego, z powodu pokonywania wzniesień i przyspieszania pojazdu. W aplikacjach przemysłowych współczynnik ten wynosi około 2.
- Silniki napędowe pojazdów muszą móc osiągać 4 do 5 razy większą prędkość maksymalną od bazowej, ze względu na jazdę po autostradzie, podczas gdy w przemyśle współczynnik ten wynosi około 2.
- Silniki elektryczne wykorzystywane w pojazdach *EV* i *HEV* muszą jednocześnie spełniać wymaganie wysokiej gęstości mocy oraz wysokiej sprawności dla szerokiego zakresu

parametrów. Jest to spowodowane chęcią redukcji masy pojazdu oraz wydłużenia jego zasięgu. W przypadku aplikacji przemysłowych istotny jest kompromis pomiędzy gęstością mocy silnika, jego sprawnością i kosztami, przy czym sprawność jest istotna dla punktu pracy silnika.

- Silniki montowane w *EV* i *HEV* powinny cechować się dużą dokładnością pracy dla stałych warunków, dobrą dynamiką i być łatwe do wysterowania dla szerokiego zakresu punktów pracy. Silniki elektryczne przemysłowe muszą spełnić te wymagania jedynie w nielicznych przypadkach.
- Silniki elektryczne montowane w pojazdach muszą spełnić rygorystyczne wymagania dotyczące warunków pracy takie, jak: szeroki zakres temperatur pracy, zmienne warunki pogodowe czy wibracje powstałe podczas jazdy pojazdu. Silniki przemysłowe zazwyczaj montowane są w jednym miejscu przy stałych warunkach pracy.

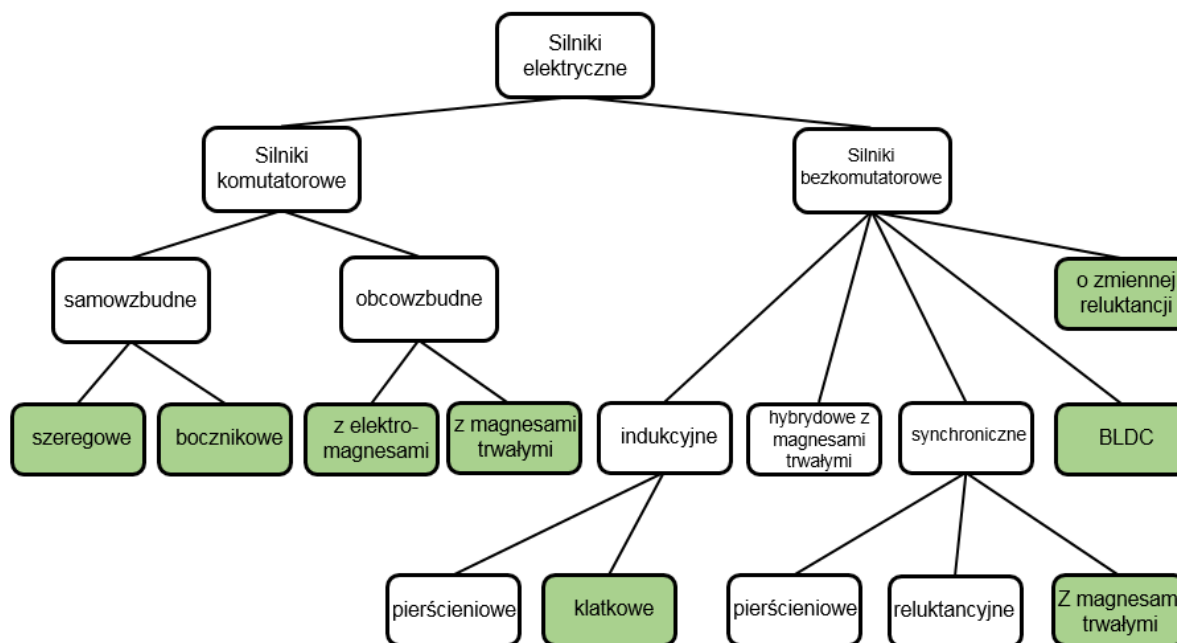
Oprócz szeregu wymagań, które silniki elektryczne muszą spełnić, istotna dla wyboru konkretnego silnika bądź jego projektu jest architektura i konfiguracja pojazdu. Do najważniejszych cech architektury pojazdu można zaliczyć następujące konfiguracje [2]:

- Konfiguracja z jednym bądź wieloma silnikami - istnieje możliwość zastosowania bądź pojedynczego silnika elektrycznego do napędu wielu różnych kół pojazdu, bądź też wykorzystania pojedynczego silnika do napędu pojedynczego koła pojazdu. Oba rozwiązania mają swoje wady i zalety. Użycie pojedynczego silnika zmniejsza wielkość napędu, masę i koszt. Jest to także rozwiązanie prostsze w sterowaniu. Rozwiązanie z wykorzystaniem wielu silników zmniejsza moc każdego z napędów oraz pomaga w równomiernym rozłożeniu masy w pojeździe. Wadą tego rozwiązania oprócz większych kosztów jest bardziej skomplikowany układ sterowania. We współczesnych pojazdach *EV* i *HEV* dominują pojazdy z pojedynczym silnikiem elektrycznym napędzającym wiele kół pojazdu.
- Rozwiązanie ze stałym bądź zmiennym przełożeniem - możliwe jest zastosowanie w pojeździe zarówno układu przełożenia napędu o stałym, niezmiennym przełożeniu, jak i zmiennego przełożenia. Pierwsze rozwiązanie jest prostsze oraz tańsze, minimalizuje także masę i gabaryty układu napędowego. Wadą tego rozwiązania są wyższe wymagania stawiane przed silnikiem napędowym pojazdu. Musi on jednocześnie spełnić wymagania odnośnie wysokiego chwilowego momentu napędowego (3 do 5 razy powyżej wartości nominalnej) oraz wysokiej prędkości obrotowej (3 do 5 razy powyżej wartości nominalnej). Drugie rozwiązanie umożliwia uzyskanie wysokiego momentu obrotowego, w przypadku niskich prędkości obrotowych oraz wysokich prędkości obrotowych, przy niższym momencie, w przypadku jazdy z dużą prędkością. Słabością tego rozwiązania jest zwiększenie kosztów, gabarytów oraz masy układu napędowego. Układ napędowy jest w tym przypadku także bardziej skomplikowany. W większości współczesnych pojazdów *EV* i *HEV* stosowane jest rozwiązanie z stałym przełożeniem.

- Rozwiązanie z przełożeniem i brakiem przełożenia - w przypadku elektrycznych silników napędowych pojazdów istnieje możliwość zastosowania silników wolnoobrotowych, które nie wymagają dodatkowej przekładni. Silniki te dostarczają większego momentu obrotowego, zaś prędkość obrotowa jest identyczna z prędkością obrotową koła. Zaletą takiego rozwiązania jest większa zwartość i prostota układu napędowego. Silniki wolnoobrotowe mają jednak niższą gęstość mocy. Z drugiej strony zastosowanie szybkoobrotowych silników umożliwia dobór silnika o wyższym współczynniku gęstości mocy. Jednocześnie silnik szybkoobrotowy wymusza zastosowanie przekładni, co komplikuje układ napędowy oraz zwiększa jego masę. W samochodach *EV* i *HEV* obie architektury są wykorzystywane, jednak zdecydowanie dominuje rozwiązanie z silnikiem szybkoobrotowym oraz przekładnią.
- Dobór odpowiedniego napięcia pracy systemu - w przypadku pojazdów *EV* i *HEV* napięcie pracy systemu może być dobrane z szerokiego zakresu. Wysoka wartość napięcia w systemie może przyczynić się do zmniejszenia kosztów i rozmiarów konwerterów i przekształtników napięcia zastosowanych w pojeździe. Wadą takiego rozwiązania jest duża liczba ogniw połączonych szeregowo, co zwiększa masę akumulatora i samego pojazdu, zmniejszając jego osiągi. Wysokość napięcia w systemie różni się znacznie dla różnych współczesnych pojazdów *EV* i *HEV*. W przybliżeniu napięcie w systemie zależy od masy baterii, które odpowiadają za około 30% masy pojazdu w przypadku *EV*. W praktyce wyższą wartość napięcia stosuje się w przypadku wyższej mocy silnika.
- Integracja z pozostałymi podzespołami elektrycznymi i elektronicznymi - elementy takie jak: konwerter, sterownik silnika, źródło zasilania czy układ przełożenia powinny ściśle współpracować z silnikiem napędowym. Z tego powodu cechy silnika muszą zostać ściśle dobrane do tych kryteriów. Dla *EV* i *HEV* ma to zdecydowanie większe znaczenie niż w przypadku silników elektrycznych o bardziej tradycyjnych, przemysłowych zastosowaniach.

Rozwój silników elektrycznych trwa od ponad 100 lat. Skutkiem tego rozwoju jest bardzo duża liczba dostępnych silników elektrycznych. Najbardziej podstawowym podziałem silników elektrycznych jest ich podział na silniki komutatorowe i bezkomutatorowe. Podstawowym kryterium podziału jest, w tym przypadku, występowanie komutatora, służącego do odwrócenia kierunku przepływu prądu elektrycznego przez uzwojenia i tym samym zmianę pola magnetycznego w silniku. Silniki elektryczne komutatorowe można podzielić na silniki szeregowo, bocznikowe, obcowzbudne z elektromagnesami i silniki z magnesami trwałymi. Silniki komutatorowe ze względu na prostotę sterowania oraz dojrzałą konstrukcję były często używane w pojazdach *EV* [2]. W późniejszym czasie nastąpił gwałtowny rozwój elektroniki i związanych z tym, sposobów sterowania silnikami. Umożliwiło to znaczny rozwój silników bezkomutatorowych. Silniki tego typu często są stosowane w przypadku pojazdów *EV* i *HEV* z powodu niskich kosztów, wysokiej sprawności i bezobsługowej pracy.

Silniki bezkomutatorowe można podzielić na silniki indukcyjne, synchroniczne, *BLDC*, o zmiennej reluktancji i hybrydowe z magnesami trwałymi. Podział silników elektrycznych został przedstawiony na rysunku rys. 4. Silniki używane w samochodach *EV* i *HEV* zostały na diagramie zaznaczone na zielono [2]. Na szczególną uwagę, w kontekście silników napędowych pojazdów, zasługują silniki indukcyjne. Jest to spowodowane niskimi kosztami, niezawodnością i dobrą sterowalnością. Drugą interesującą grupą są silniki *BLDC*. Są one droższe, osiągają jednak bardzo dobre parametry gęstości mocy oraz sprawność, przy jednoczesnej dobrej sterowalności silnika.



Rys. 4 Podział silników elektrycznych [2]

Wybór konkretnego silnika do pojazdu jest procesem trudnym i oprócz wymienionych powyżej cech należy wziąć pod uwagę indywidualne wymagania każdego pojazdu takie jak koszty lub specyficzne dla danego projektu potrzeby. W każdym przypadku wybór jednostki napędowej stanowi kompromis pomiędzy wieloma cechami i wymaganiami.

Magazyny energii w pojazdach *HEV* i *EV* stanowią bardzo istotny element całego pojazdu, wyróżniający go spośród konwencjonalnych samochodów z silnikiem spalinowym. W niniejszej rozprawie, przez magazyn energii rozumie się urządzenie zdolne do oddawania energii w pojeździe (rozładowywanie) oraz przyjmowania jej z zewnątrz (ładowanie) [1, 5]. Magazyny energii stosowane w pojazdach *EV* i *HEV* muszą spełnić liczne kryteria, takie jak: określona moc i pojemność, wysoka sprawność, określony sposób konserwacji, koszt, bezpieczeństwo użytkowania oraz powinny być przyjazne dla środowiska. Jednym z dwóch kluczowych parametrów wszelkich magazynów energii jest ich pojemność. Tradycyjnie jednostką energii stosowaną w układzie SI jest dżul (J), jednak ze względu na małą wartość tej jednostki, w porównaniu z pojemnościami współczesnych magazynów energii, znacznie częściej korzysta się z takich jednostek jak kWh lub najczęściej w przypadku baterii Ah.

Pojemność 1 kWh oznacza ilość energii, jaką zużywa urządzenie o mocy 1 kW przez godzinę. W przypadku akumulatorów sytuacja jest bardziej skomplikowana, gdyż należy także wziąć pod uwagę dodatkowe czynniki, takie jak temperatura czy natężenie prądu rozładowania. Pojemność akumulatorów określana jest dla optymalnych warunków pracy akumulatora, określonych w dokumentacji technicznej. Zwiększenie lub zmniejszenie temperatury pracy akumulatora poza zakres przewidziany w dokumentacji technicznej, lub zwiększenie natężenie prądu rozładowania może istotnie ograniczyć rzeczywistą ilość energii możliwej do dostarczenia przez akumulator. W przypadku pojemności w Ah, możliwe jest przeliczenie energii na Wh. Pojemność ta podawana jest dla nominalnego napięcia akumulatora. Podobnie jak ma to miejsce w przypadku pojemności podawanej w Wh, pojemność nominalna w Ah jest energią możliwą do dostarczenia przez akumulator w optymalnych, podanych w dokumentacji technicznej danych. Wzór pozwalający przeliczyć ilość dostępnej energii w magazynie z kWh na J dany jest poniższą zależnością:

$$E[J] = E[kWh] * 1000 * 3600 \quad (1)$$

Pojęciem mocy magazynu energii nazywamy maksymalną moc, chwilową bądź ciągłą, możliwą do dostarczenia przez magazyn energii w bezpieczny sposób. Zazwyczaj moc magazynów energii podawana jest w kW. Z pojęciem mocy lub pojemności związane jest pojęcie gęstości mocy bądź energii. Wyrażamy ją w ilości energii możliwej do zmagazynowania lub mocy możliwej do rozładowania z magazynu energii, dzielonej przez jednostkę masy bądź objętości. Najczęściej gęstość mocy wyraża się w kW/kg lub kW/l w przypadku pojemności, zaś gęstość energii w kWh/kg lub kWh/l. Oba parametry są bardzo istotne z punktu widzenia pojazdów *EV* i *HEV*. Spośród nich istotniejszym parametrem jest gęstość mocy i energii w odniesieniu do masy. Niższa wartość gęstości mocy i energii w stosunku do masy skutkuje zwiększeniem masy pojazdu, przy identycznych innych parametrach, co przekłada się na możliwy do uzyskania zasięg pojazdu. W przypadku gęstości mocy i energii w stosunku do objętości, przy niższym współczynniku gęstości, zmniejsza się jedynie pojemność pojazdu. W przypadku pojazdów *EV* pojemność jest istotniejszym parametrem niż w przypadku *HEV*, które posiadają poza napędem elektrycznym także napęd konwencjonalny oparty na silniku spalinowym. Dla wygody ilość energii w akumulatorach i superkondensatorach podaje się jako stopień naładowania (*ang. state of charge, SOC*). Jest to stosunek energii zmagazynowanej w urządzeniu w danym momencie do całkowitej pojemności magazynu energii. *SOC* podaje się w procentach. Pojęciem pokrewnym jest stopień rozładowania (*ang. degree of discharge, DOD*). Jest to iloraz ilości energii rozładowanej w urządzeniu do całkowitej ilości energii mogącej być zmagazynowanej w akumulatorach lub superkondensatorach, również podawany w procentach. *SOC* jest miarą znacznie bardziej popularną. Pomiędzy *SOC* i *DOD* zachodzi związek [2]:

$$DOD = 100\% - SOC \quad (2)$$

Akumulatory są podstawowym magazynem energii w *EV* i *HEV*, cechują się one wysoką pojemnością oraz bardzo często wysoką mocą. Akumulatory zazwyczaj składają się z wielu ogniw. Mogą one być łączone szeregowo lub równoległe, zwiększając napięcie pracy lub wydajność prądową akumulatora. Ogniwa stanowią osobną, zamkniętą całość, w których za sprawą zachodzących procesów fizyko-chemicznych, wytwarzana jest energia. W każdym ogniwie można wyróżnić anodę i katodę. Podczas rozładowywania na anodzie przeprowadzana jest reakcja utleniania, wymuszając uwolnienie elektronu, który następnie poprzez obwód zewnętrzny transportowany jest do katody, gdzie zachodzi reakcja redukcji. Podczas ładowania proces ten jest odwracany. Podczas przejścia przez obwód zewnętrzny elektron wykonuje pracę [2]. Użyte materiały podlegające reakcjom oraz same elektrody różnią się w zależności od typu stosowanego ogniwa. Proces ładowania i rozładowywania akumulatorów nie odbywa się bez strat energii. W przypadku akumulatorów proces strat objawia się poprzez spadek napięcia. Stąd sprawność ogniwa podczas rozładowywania można wyrazić wzorem [1]:

$$\eta = \frac{V}{V_0} \quad (3)$$

Zaś podczas ładowania:

$$\eta = \frac{V_0}{V} \quad (4)$$

Gdzie η oznacza sprawność, V_0 napięcie termodynamiczne, zaś V napięcie pracy ogniwa. Napięcie na zaciskach ogniwa jest niższe podczas rozładowywania i wyższe podczas ładowania niż potencjał elektryczny wytwarzany w reakcjach chemicznych zachodzących w ogniwie. Straty energii odprowadzane są w postaci ciepła. Sprawność baterii w przypadku ładowania jest wysoka dla niskiego *SOC*, zaś podczas rozładowywania dla wysokiego *SOC*. Sprawność całego cyklu ładowania i rozładowywania jest najwyższa dla środkowego zakresu *SOC*. Z tego powodu układ zarządzania energią w *HEV* powinien, w miarę możliwości utrzymywać, *SOC* w środkowym zakresie, by uniknąć strat energii oraz nadmiernego nagrzewania się akumulatorów, mogącego skutkować ich uszkodzeniem. Spośród technologii używanych w akumulatorach można wyróżnić akumulatory kwasowo-ołowiowe, akumulatory na bazie niklu takie jak: niklowo-żelazowe, niklowo-kadmowe, oparte o nikiel i wodorki metali oraz bazujące na związku litu takie jak: litowo-polimerowe, litowo-jonowe oraz sodowo-chlorkowo-niklowe. Każda z technologii została krótko scharakteryzowana poniżej:

- Akumulatory kwasowo-ołowiowe. Należą one do najstarszych typów akumulatorów. Rozwój akumulatorów kwasowo-ołowiowych trwa od ponad 100 lat, co sprawia że ich technologia jest bardzo dojrzała [2]. Jest to zaletą ze względu na bardzo dobre poznanie technologii. Jednocześnie zmniejsza to pole do dalszego rozwoju akumulatorów opartych na tej technologii. Akumulatory kwasowo-ołowiowe były stosowane w pierwszych samochodach *EV* i *HEV*, jednak w porównaniu do akumulatorów innych typów posiadają one gorsze parametry, istotne

z punktu widzenia ich montażu jako magazynu energii w pojeździe. Gęstość energii w akumulatorach kwasowo-ołowiowych jest niska i kształtuje się pomiędzy 20 a 40 Wh/kg [16-17]. Także gęstość mocy tych akumulatorów nie jest wysoka i kształtuje się na poziomie około 200W/kg [2]. Samorozładowanie i żywotność w postaci ilości cykli także jest niska w porównaniu z innymi typami akumulatorów [16]. Niewątpliwą zaletą tego typu akumulatorów jest ich cena. Z tego powodu akumulatory te mogą być dobrym wyborem w przypadku pojazdów *EV* o bardzo niewielkim zasięgu [16].


- Akumulatory niklowo-żelazowe zostały wynalezione na początku XX wieku. Baterie tego typu są narażone na gazowanie, korozję i samorozładowanie. Z tego powodu ich obsługa jest skomplikowana. Ich największą zaletą jest duża gęstość mocy w porównaniu do akumulatorów kwasowo-ołowiowych, oraz duża żywotność sięgająca około 2000 cykli. Aplikacje nie obejmowały pojazdów *EV* i *HEV*, a dotyczyły lokomotyw w kopalniach, ręcznych wózków transportowych czy wózków widłowych [1].
- Akumulatory niklowo-kadmowe historycznie zostały rozwinięte z akumulatorów niklowo-żelazowych. Ogniwa tego typu znacznie rozwinęły się od czasu ich wynalezienia. Jest to spowodowane ich licznymi zaletami. Zaliczają się do nich: wysoka gęstość mocy (ponad 220 W/kg), wysoka gęstość energii (ok 56 Wh/kg i 110 Wh/l), duża żywotność (do 2000 cykli), szeroki zakres temperatur pracy (- 40 do 85°C), niski efekt samorozładowania (poniżej 0,5 % na dzień), możliwość szybkiego ładowania, płaska charakterystyka rozładowania w szerokim zakresie oraz duża tolerancja na przeciążenia elektryczne i mechaniczne. Napięcie nominalne pojedynczego ogniwa wynosi 1,2 V. Największą wadą tego typu ogniw jest wykorzystanie, szkodliwego dla środowiska oraz człowieka kadmu do budowy baterii. Z tego powodu w Unii Europejskiej ich wykorzystanie zostało ograniczone. Do innych wad należy zaliczyć wysoki koszt i relatywnie niskie napięcie nominalne na pojedynczym ogniwie. Ogniwa znalazły wykorzystanie w wielu pojazdach *EV* i *HEV*, takich jak Chrysler TE Van, Citroën AX, Mazda Roadster, Mitsubishi EV, Peugeot 106 czy Renault Clio [1-2, 17].
- Akumulatory NiMH - są to akumulatory oparte na niklu i wodorkach metali. Są one dostępne na rynku od 1992 roku. Podstawowa różnica w ich budowie, w stosunku do akumulatorów niklowo-kadmowych, polega na zastąpieniu katody wykonanej z kadmu katodą wykonaną z wodorków metali, w których uwięziony jest wodór. Akumulatory tego typu cechują się podobnymi osiąganiami co akumulatory niklowo-kadmowe, przy jednoczesnym braku toksycznego kadmu w ich budowie. Z tego powodu, stopniowo akumulatory NiMH wypierają z rynku akumulatory niklowo-kadmowe. Do zalet akumulatorów NiMH można zaliczyć: wysoką gęstość mocy (200- 300W/kg), wysoką gęstość energii (ponad 70 Wh/kg i 120 Wh/l), możliwość szybkiego ładowania, płaską charakterystykę rozładowania w szerokim zakresie oraz brak efektu pamięci. Ich główną wadą jest wysoka cena. Napięcie nominalne pojedynczego ogniwa wynosi w tym przypadku 1,2 V. Akumulatory tego typu były montowane w wielu

pojazdach *EV* i *HEV*, takich jak: Solectric GT Force *EV* oraz w modelu Toyota Prius i Honda Insight [1-2, 16- 17].

- Akumulatory litowo-polimerowe - akumulatory tego typu cechują się dobrymi osiąganiami. Nominalne napięcie dla pojedynczego ogniwa wynosi 3V. Ich głównymi zaletami są: wysoka gęstość mocy (około 315 W/kg), bardzo wysoka gęstość energii (155 Wh/kg i 220 Wh/l), niski efekt samorozładowania (rzędu 0,5 % na miesiąc), możliwość produkcji baterii o różnych kształtach, oraz bezpieczeństwo. Głównymi wadami tego typu akumulatorów jest wysoki koszt oraz niski zakres temperatur pracy. Podjęto próby wprowadzenia akumulatorów tego typu na rynek pojazdów *EV* i *HEV* [1-2, 17].
- Akumulatory litowo-jonowe - cechują się bardzo dobrymi parametrami. Są one obecnie najczęściej montowane w pojazdach *EV* i *HEV*. Budowa baterii opiera się na zastosowaniu związków litu. Nominalne napięcie pojedynczego ogniwa wynosi 4 V. Zaletami akumulatorów litowo-jonowych są bardzo dobre parametry użytkowe: gęstość energii rzędu 120 Wh/kg i 200 Wh/l, gęstość mocy 260 W/kg, oraz duża żywotność sięgająca około 1000 cykli. Największymi wadami jest wysoki koszt, rosnący ze względu na popularność ich wykorzystania oraz duży efekt samorozładowania (około 10%). Technologia akumulatorów litowo-jonowych znana jest od ponad 25 lat, jednak ciągle istnieje w niej bardzo duże pole do rozwoju tych baterii. Akumulatory te są najbardziej obiecującą technologią w perspektywie najbliższych lat. Przykładem pojazdów, w których zastosowano akumulatory technologii litowo-jonowej mogą być: Nissan FEV, Nissan Prairie Joy, Nissan Altra oraz pojazdy marki Tesla [1-2, 16-17].
- Akumulatory sodowo-chlorkowo-niklowe - należą one do grupy najnowszej technologii w dziedzinie akumulatorów. Mają one liczne zalety, do których można zaliczyć: niski koszt (rzędu jednej trzeciej kosztów akumulatorów litowo-jonowych), bezpieczeństwo, wysoką gęstość energii (rzędu 120 Wh/kg) oraz dużą żywotność (około 1000 cykli). Główną wadą tego typu akumulatorów jest niska gęstość mocy w porównaniu z akumulatorami litowo-jonowymi, wynosząca około 150 W/kg. Niska gęstość mocy powoduje, że tego typu akumulatory ,w przypadku zastosowań *EV* i *HEV*, powinny być łączone z dodatkowym źródłem energii, takim jak superkondensatory [16].

Superkondensatory (*ang ultracapacitors*) - są rodzajem kondensatorów o zwiększonej pojemności. W stosunku do akumulatorów cechują się one znacznie niższą gęstością energii i znacznie większą gęstością mocy, która może sięgać ponad 3kW/kg [1]. Z powodu spadku napięcia na zaciskach kondensatora wraz ze spadkiem jego naładowania (*SOC*) oraz niską gęstością energii, nie mogą być one używane jako jedyny magazyn energii w pojeździe *EV* lub *HEV*. Jednakże jego zalety, do których można zaliczyć przede wszystkim bardzo wysoką gęstość mocy, umożliwiają jego wykorzystanie jako pomocniczego źródła zasilania. Superkondensatory dzięki wysokiej gęstości mocy umożliwiają także bardziej efektywne hamowanie z odzyskiem energii w stosunku do akumulatorów [2]. Dotyczy to

zwłaszcza tzw. hybrydowego układu zasilania *EV* i *HEV*. Pozwala to wykorzystać zalety zarówno akumulatorów jak i superkondensatorów. Stosunek średniej mocy do mocy szczytowej w przypadku pojazdów *EV* może sięgać nawet 1:16. W przypadku częstego zatrzymywania pojazdu, na przykład w ruchu miejskim, ilość energii związana z przyspieszaniem i hamowaniem odpowiada za około 2/3 całej zużytej przez pojazd energii. W hybrydowym układzie zasilania podczas normalnej jazdy wykorzystywana jest energia zmagazynowana w akumulatorze. W trakcie zwiększonego zapotrzebowania na energię, podczas ruszania i pokonywania wzniesień, energia może pochodzić z superkondensatorów. Ładowanie superkondensatorów odbywa się podczas hamowania z odzyskiem energii i w trakcie zmniejszonego zapotrzebowania na energię w pojeździe, za pomocą energii pochodzącej z akumulatorów. W takim układzie akumulatory rozładowywane są z mniejszą mocą, co pozytywnie wpływa na ich żywotność [2]. W zależności od budowy konkretnej baterii superkondensatorów gęstość mocy energii wynosi zazwyczaj kolejno 2000-4000 W/kg i 2-4 kWh/kg [1].



Rys. 5 Zestawienie gęstości mocy i energii dla wybranych technologii magazynów energii [16].

Zestawienie gęstości mocy i energii dla poszczególnych technologii magazynów energii przedstawiono na Rys. 5 [16]

Szybkoobrotowe koła zamachowe – w przeciwieństwie do akumulatorów i superkondensatorów, energia, w przypadku kół zamachowych magazynowana jest w postaci mechanicznej. Koncepcja magazynowania energii w do napędzania pojazdów w kole zamachowym nie jest nowym pomysłem. Ponad 30 lat temu przedsiębiorstwo Oerlikon Engineering Company w Szwajcarii zbudowało autobus napędzany wyłącznie za pomocą masywnego koła zamachowego o masie 1500 kg i roboczej prędkości obrotowej około 300 obr/min. Koło zamachowe było napędzane przez silnik elektryczny, w trakcie postoju na przystankach [1]. W dzisiejszych czasach myśląc o kołach zamachowych do napędu pojazdów należy spojrzeć raczej na lekkie, kilkunastokilogramowe, kompozytowe koła zamachowe o roboczej prędkości obrotowej sięgającej kilkudziesięciu tysięcy obrotów na minutę. Niektóre prototypy osiągają prędkości 60000 obr/min. Niestety w praktyce trudno jest zastosować koła zamachowe do napędu pojazdu. Jest to spowodowane koniecznością posiadania przekładni o wysokiej sprawności i trwałości umożliwiającej płynną zmianę przełożenia w bardzo szerokim zakresie. Dodatkową trudnością jest występowanie efektu żyroskopowego i związanych z nim sił podczas zmiany kierunku jazdy samochodu [1-2]. Z tych powodów szybkoobrotowe koła zamachowe nie są obecnie stosowane w pojazdach.

Zespół silnika spalinowego wraz z generatorem - zadaniem tego zespołu jest zapewnienie możliwości doładowania magazynów energii obecnych w pojeździe, w celu zapobiegnięcia ich całkowitemu rozładowaniu. W przypadku pojazdów *HEV* o konfiguracji równoległej, generator nie jest na stałe połączony z silnikiem. Z kolei silnik spalinowy w wypadku pojazdów *HEV* o konfiguracji szeregowej ma zadanie pomocnicze i jego parametry pracy różnią się w stosunku do silników spalinowych montowanych w konwencjonalnych samochodach. W tradycyjnym samochodzie często dochodzi do zmiany mocy chwilowej silnika, w przypadku silników spalinowych w *HEV* o konfiguracji szeregowej zazwyczaj mamy do czynienia z pracą silnika przez dłuższy czas przy stałych parametrach. Z tego powodu w przypadku tego typu pojazdów najistotniejszym parametrem silnika jest maksymalna moc dla pracy ciągłej. W przypadku konfiguracji równoległej silnik powinien być w stanie napędzić pojazd podczas normalnej jazdy, ze stałą prędkością, na płaskim lub umiarkowanie pochyłym terenie, bez wspomaganie silnikiem elektrycznym. Jednocześnie średnia moc silnika powinna być wyższa niż średnia moc zużywana przez pojazd [1]. Z tych kryteriów wynika bezpośrednio dobór wielkości silnika do pojazdu *HEV* o konfiguracji równoległej. W przypadku pojazdów *HEV* o konfiguracji szeregowej istnieją dwa kryteria doboru silnika. Moc silnika spalinowego powinna być wystarczająca by umożliwić jazdę pojazdu przez dłuższy czas, przy dużej prędkości (np. na autostradzie) oraz zapewnić wystarczającą poziom mocy podczas jazdy z zatrzymaniami (np. podczas ruchu w mieście), tak by poziom energii w akumulatorach utrzymywał się na stałym poziomie [1]. Zespół silnika oraz generatora muszą być dobrane tak, by spełnić obydwie wymagania łącznie ,umożliwiając poprawną pracę pojazdu.

2.3 Sposoby realizacji optymalizacji zużycia energii w pojeździe HEV o konfiguracji szeregowej typu plug in.

Zagadnienie optymalnego wykorzystania energii zmagazynowanej w pojeździe *HEV* w postaci energii elektrycznej w akumulatorach i superkondensatorach oraz paliwie nie jest zagadnieniem nowym [7]. Przez optymalne, rozumie się takie gospodarowanie energią w samochodzie, aby ograniczyć jej zużycie do pokonania określonej trasy w określonych warunkach drogowych, przy jednoczesnym zaspokojeniu zapotrzebowania energetycznego pojazdu. Celem optymalizacji może być więc minimalizacja zużycia energii w pojeździe lub też minimalizacja strat energii w pojeździe. W obu przypadkach zastosowanie optymalizacji skutkuje zwiększeniem zasięgu pojazdu, przy zachowaniu pozostałych parametrów. Innym celem optymalizacji może być ograniczenie kosztów związanych z pokonaniem określonej trasy. W takim przypadku, zużyta energia i paliwo przeliczane są na koszty wyrażone najczęściej w pieniądzu lub tzw. ekwiwalencie paliwa. Dodatkowym kryterium może być także minimalizacja zużycia elementów pojazdu, ze szczególnym uwzględnieniem akumulatorów pojazdu, stanowiących znaczną część kosztów produkcji całego pojazdu. Aby było możliwe przedstawienie stosowanych sposobów realizacji optymalizacji zużycia energii, konieczne jest wprowadzenie kilku kluczowych pojęć.

Energochłonność, zwana też zapotrzebowaniem energetycznym pojazdu, rozumie się jako ilość energii, która musi zostać pobrana z magazynów energii pojazdu *HEV* o konfiguracji szeregowej, aby możliwe było poruszanie się samochodem w danych warunkach z daną prędkością. Zapotrzebowanie energetyczne nie uwzględnia, w tych warunkach, zapotrzebowania na energię przez dodatkowe układy pojazdu takie jak: światła, radio, klimatyzację itd., skupiając się tylko na zapotrzebowaniu na energię przez układ napędowy.

Profil prędkości (*ang. velocity profile*) oznacza funkcję prędkości pojazdu od czasu. Profil prędkości podaje dokładne wartości prędkości pojazdu w danym czasie. Jest zależny od wielu czynników takich jak: aktualne warunki, moc pojazdu, sposób prowadzenia pojazdu przez kierowcę, trasa oraz pogoda i inne czynniki o charakterze losowym takie jak interakcja z innymi uczestnikami ruchu drogowego. Profile prędkości można podzielić na rzeczywiste - będące historycznym zapisem prędkości konkretnego pojazdu w funkcji czasu oraz sztuczne - uzyskane arbitralnie lub za pomocą różnych algorytmów. Sztuczne profile prędkości są zazwyczaj silnie liniowe. Wykorzystywane są na przykład do przeprowadzania testów zużycia paliwa dla pojazdów wchodzących na rynek. Rzeczywiste profile prędkości cechują się silną nieliniowością i w praktyce niemożliwe jest uzyskanie 2 identycznych profili prędkości. Rzeczywiste profile prędkości cechują się zazwyczaj stałym, małym krokiem czasowym, przez co można przyjąć, że odwierciedlają one prędkość pojazdu w sposób ciągły. Zazwyczaj mówiąc o profilach prędkości, mamy na myśli rzeczywisty profil prędkości dla konkretnego pojazdu i w konkretnych warunkach. Profil prędkości najczęściej przedstawiany jest w postaci wykresu.

Na podstawie profili prędkości możliwe jest określenie, w sposób przybliżony zapotrzebowania na energię w pojeździe [18].

Profil wzniesień (*ang. hill profile*) - jest funkcją wysokości względnej drogi na trasie pojazdu od pokonanego dystansu. Pozwala on na przedstawienie informacji o nierównościach terenu występujących na trasie. Pokonywanie nierówności terenu znacząco wpływa na zapotrzebowanie energetyczne pojazdu, zwiększając zapotrzebowanie podczas wjeżdżania pod górkę i zmniejszając zapotrzebowanie podczas zjazdu z góry. Profil wzniesień stanowi z tego powodu bardzo istotną informację. Najbardziej popularną formą przedstawienia profilu prędkości jest wykres wysokości od drogi.

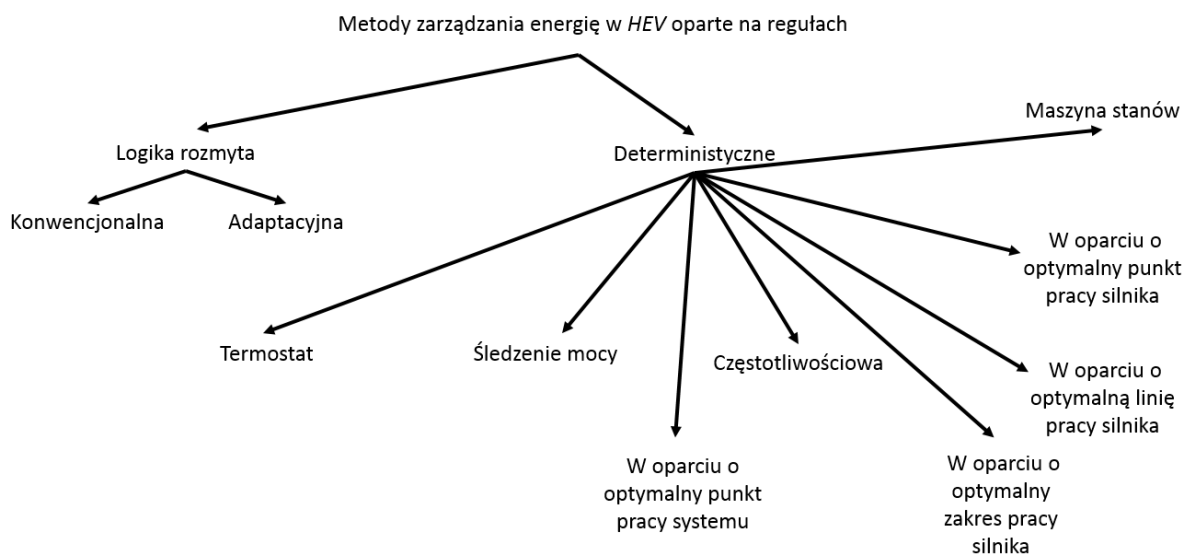
Hamowanie z odzyskiem energii (*ang. regenerative braking*) polega na odzyskiwaniu części energii kinetycznej samochodu i zamianie jej na energię elektryczną za pomocą silnika elektrycznego pojazdów *EV* i *HEV*. Energia elektryczna wytwarzana jest w silniku elektrycznym, poprzez odwrócenie jego pracy. Energia ta jest następnie magazynowana w akumulatorach i superkondensatorach pojazdu. Odzysk energii może się odbywać podczas hamowania pojazdu w trakcie normalnej jazdy oraz podczas zjazdu z przewyższeń terenu [6]. Energia kinetyczna wytracana przez pojazd stanowi znaczną część całkowitej energii zużywanej przez pojazd. Dotyczy to zwłaszcza obszarów miejskich, na których, podczas przejazdu z częstymi zatrzymaniami, energia hamowania stanowi ponad 25%. W przypadku dużych miast, takich jak Nowy Jork, poziom energii odzyskiwanej podczas hamowania może osiągnąć do 70% całkowitej energii zużywanej przez pojazd [1]. Z powyższych liczb jasno wynika, że odzysk energii z hamowania znacząco poprawia sprawność pojazdu. Silnik poprzez odwróconą pracę wytwarza moment hamujący pojazd. Układ hamulcowy jest zdecydowanie jednym z najbardziej newralgicznych pod względem bezpieczeństwa układów pojazdu. Musi on spełniać szereg kryteriów. Do najważniejszych należą: zapewnienie maksymalnej siły hamowania w sytuacjach awaryjnych wymagających natychmiastowego zatrzymania pojazdu, zapewnienie równomiernego rozkładu siły hamowania na poszczególne osie oraz zapewnienie sprzężenia zwrotnego do kierowcy w postaci odczucia siły hamowania na pedale hamulca [2]. Niestety moment hamujący możliwy do wytworzenia przez silnik elektryczny pojazdu jest znacząco mniejszy od wymaganego momentu do hamowania. Dotyczy to zwłaszcza momentu hamującego dla sytuacji niebezpiecznych, w których konieczne jest jak najszybsze zatrzymanie pojazdu. Dodatkowo skuteczność hamowania z odzyskiem energii jest znacznie niższa przy niskich prędkościach pojazdu, co wynika z budowy silnika pojazdu. Równomierna siła hamowania na poszczególne osie także jest trudna do zapewnienia ze względu na napęd, który najczęściej występuje tylko na jednej z osi pojazdu. Wreszcie zapewnienie kierowcy właściwego dla hamowania odczucia na pedale hamulca jest trudne do osiągnięcia bez zastosowania elementów hydraulicznych. Z tych powodów w pojazdach *EV* i *HEV* oprócz hamowania z odzyskiem energii używany jest konwencjonalny hamulec hydrauliczny. W przypadku umiarkowanego wytracania prędkości hamowanie odbywa się odzyskiem energii. W przypadku większego zapotrzebowania na siłę hamującą w pojeździe uruchamiany jest hamulec hydrauliczny, zwiększający siłę hamowania do

wymaganej wartości. Samo sterowanie hamulcem hydraulicznym odbywa się elektronicznie i nie występuje bezpośrednie połączenie hydrauliczne pedału hamulca z hamulcami na kołach pojazdu [1-2].

Zagadnieniu optymalnego zarządzania energią (*ang. energy management*) w pojazdach *HEV* poświęcono w ostatnich latach bardzo wiele uwagi [8]. Wynikiem tych prac były setki artykułów naukowych poruszających to zagadnienie i dotyczących różnych metod rozwiązania tego problemu [6]. Dotyczą one samochodów *HEV* o różnych architekturach, [15, 19-25], a także różnych typach samego pojazdu, obejmujących samochody osobowe [26], ciężarówki [15, 27] oraz autobusy [23, 12, 28]. Zarządzanie energią w pojazdach *HEV* można rozważać pod kątem różnych aspektów, takich jak: aktualny stan wiedzy, ogólne formułowanie problemu zarządzania energią w pojeździe, charakterystyka i wyniki różnych rodzajów strategii, ich wzajemne porównywanie oraz wpływ poszczególnych czynników i parametrów konkretnych metod na wyniki uzyskiwane w tych metodach [6].

Energia potrzebna do napędzenia pojazdu *HEV* o konfiguracji szeregowej może być pozyskiwana z układu generatora z silnikiem spalinowym, bądź magazynów energii. Magazyny energii w takim pojeździe mogą być doładowywane w trakcie jazdy z układu generatora z silnikiem spalinowym, bądź z wykorzystywania odzysku energii z hamowania. Zadaniem układu zarządzania energią w *HEV* jest taki podział strumienia energii, pobieranej bądź pochodzącej z silnika elektrycznego pojazdu, pomiędzy magazyny energii występujące w pojeździe, aby minimalizować funkcję kosztu. Dodatkowo układ decyduje o momencie załączenia i ilości wykorzystywanej mocy przez układ generatora wraz z silnikiem oraz o sposobie wykorzystania tej mocy. Cały proces optymalizacji sprowadza się więc do znalezienia takiej sekwencji podziałów mocy, która zapewnia minimalizację funkcji kosztów pojazdu, dla całego czasu przejazdu [29]. Funkcja kosztów może przybierać różne formy i zależy od budowy samego pojazdu oraz celu prowadzonej optymalizacji. Może nim być przykładowo: minimalizacja całkowitej emisji CO₂, minimalizacja użycia silnika spalinowego w pojeździe, minimalizacja kosztów przejazdu, minimalizacja strat energii, czy też maksymalizacja żywotności komponentów pojazdu, takich jak baterie.

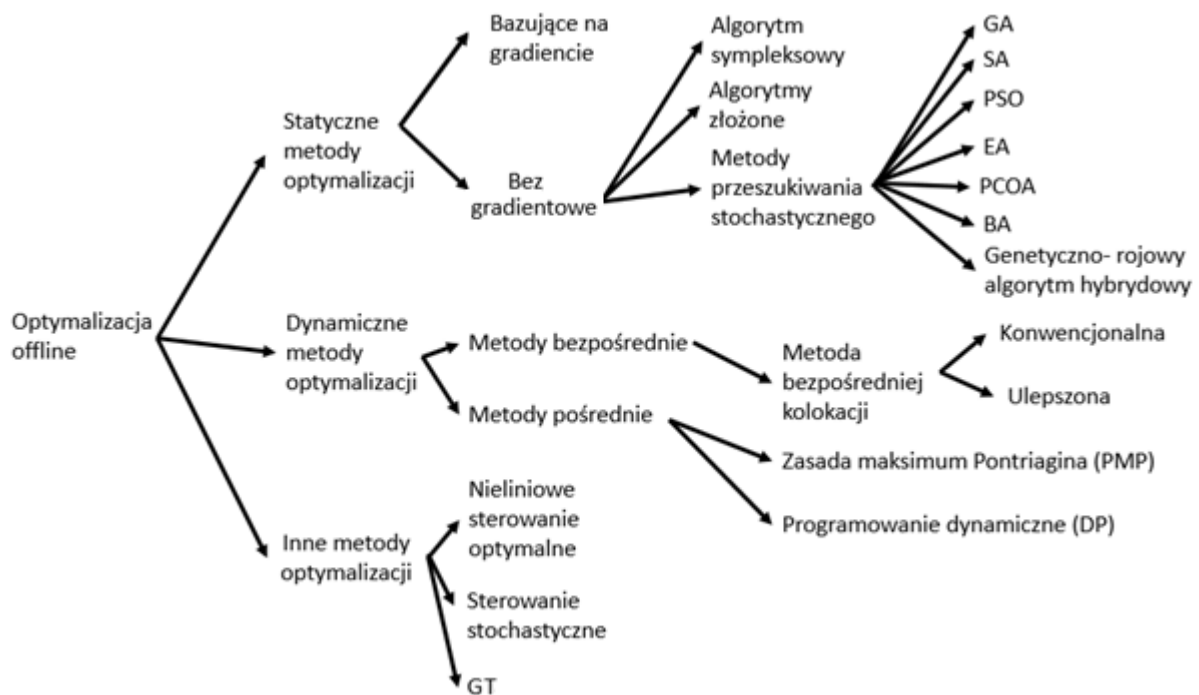
Najbardziej podstawowy podział metod optymalnego zarządzania energią w pojeździe *HEV* obejmuje strategie oparte na regułach (*ang. rule-based*) oraz metody bazujące na optymalizacji. Metody oparte na regułach wykorzystują intuicję, doświadczenie projektantów oraz modele matematyczne pojazdu. Przy ich stosowaniu zazwyczaj profil prędkości pojazdu nie jest znany a priori [8]. Metody optymalizacji bazują na analitycznych i numerycznych metodach optymalizacji, za pomocą których można znaleźć najbardziej optymalny sposób zarządzania energią w pojeździe. W przypadku obu powyższych grup metod można wyróżnić szereg podgrup i konkretnych metod oraz algorytmów [8]. W ramach strategii opartych na regułach można wyróżnić następujące typy strategii: strategia typu termostat (*ang. thermostat*) (włącz/wyłącz), śledzenia mocy (*ang. power follower*), maszyny stanów (*ang. state machine-based*), oparty o optymalny punkt lub zakres pracy, częstotliwościową (*ang. frequency-based*) oraz osobną grupę opartą o logikę rozmytą (*ang. fuzzy logic*) [7-8]. Szczegółowy podział metod zarządzania energią w pojeździe *HEV*, opartych o reguły, przedstawiono na Rys. 6 [7-8].



Rys. 6. Podział metod zarządzania energią w HEV w oparciu o reguły[7-8]

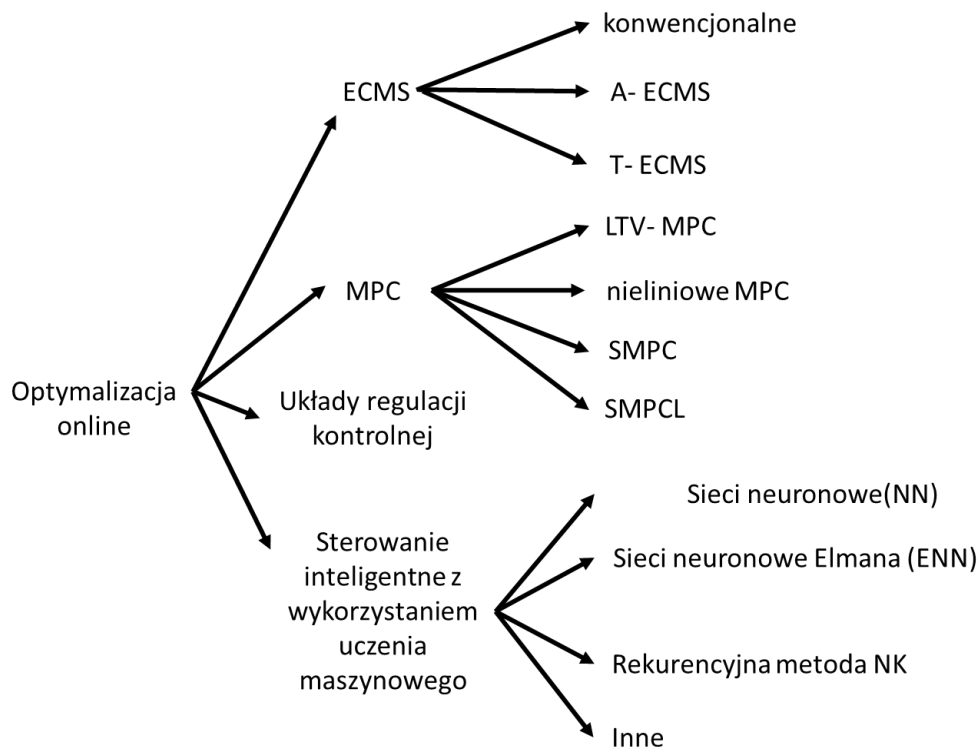
Strategie oparte na optymalizacji można podzielić na strategie realizowane na podstawie wcześniejszej znajomości trasy (ang. *offline optimization* lub *global optimization*) oraz strategie realizowane w czasie rzeczywistym (ang. *online optimization* lub *real-time optimization*). W grupie strategii offline wyróżnić można wiele algorytmów, z których najistotniejsze to: programowanie liniowe (ang. *LP linear programming*), programowanie dynamiczne (ang. *DP, dynamic programming*), algorytmy genetyczne (ang. *GA, genetic algorithm*) oraz symulowanego wyżarzania (ang. *SA, Simulated annealing*). Podział strategii offline przedstawiono na Rys. 7. Strategie online koncentrują się wokół takich metod, jak: strategia minimalizacji zużycia zastępczego energii (ang. *ECMS, equivalent consumption minimization strategy*), sterowanie predycyjne (ang. *MPC, model predictive control*), układy regulacji kontrolnej (ang. *robust control approach*) czy sterowanie inteligentne (ang. *intelligent controls*). Podział strategii online został przedstawiony na Rys. 8.

Spośród metod zarządzania energią w HEV opartych na regułach, najprostsze są strategie deterministyczne. Są one pierwotne w stosunku do strategii wykorzystujących logikę rozmytą. Wykorzystują one stały, określony z góry zestaw reguł, na podstawie, których odbywa się zarządzanie energią w pojeździe. Najprostszą strategią deterministyczną jest tzw. strategia termostatu [30]. Jest ona stosowana wyłącznie w szeregowych pojazdach HEV. W ramach strategii zespół silnika wraz z generatorem pojazdu uruchamiany jest tak, by pracować w swym optymalnym punkcie pracy ze względu na sprawność. Poziom energii w akumulatorach utrzymywany jest pomiędzy



Rys. 7. Podział metod zarządzania energią typu offline w *HEV* [7-8]

dwoma ustalonymi poziomami. Pierwszy, niższy, odpowiada za moment uruchomienia silnika spalinowego wraz z generatorem w celu doładowania baterii, drugi odpowiada za moment, w którym ładowanie baterii zostaje wyłączone [28]. Strategia ta umożliwia uzyskanie wysokiej sprawności modułu silnika spalinowego i generatora. Sprawność całego pojazdu pozostaje jednak dużo niższa [8]. W przypadku strategii polegających na śledzeniu mocy, zapotrzebowanie energetyczne pojazdu pokrywane jest zależnie od aktualnego zapotrzebowania na moc w pojeździe. Przykładem może być strategia, w której występuje kilka trybów pracy. W pierwszym, występującym podczas łagodnej jazdy i niskiego zapotrzebowania na energię, energia w całości pochodzi z baterii pojazdu, zaś silnik spalinowy nie pracuje. Podczas dużego zapotrzebowania na energię, pochodzi ona zarówno z baterii, jak i silnika spalinowego. Podczas jazdy z góry, bądź hamowania, wykorzystywane jest hamowanie z odzyskiem energii, podczas którego baterie są doładowywane. W trakcie normalnej jazdy baterie także mogą być doładowywane przez silnik spalinowy. Podobna strategia została z powodzeniem, komercyjnie, zastosowana w *HEV* o strukturze szeregowo-równoległej Toyota Prius [31]. Wadą



Rys. 8. Podział metod zarządzania energią typu online w *HEV* [7-8]

tego rozwiązania jest niska całkowita sprawność wykorzystania energii w pojeździe [8]. Pewnym rozwinięciem tej strategii jest, zaproponowana przez Jahnsa, strategia oparta na maszynie stanów [32]. W pierwszym kroku budowy maszyny stanów zidentyfikowano wszystkie możliwe stany dla poszczególnych podzespołów. Przykładowo dla silnika spalinowego były to stany włączony i wyłączony. Następnie utworzono wszystkie możliwe kombinacje stanów dla poszczególnych komponentów oraz zidentyfikowano stany niemożliwe do uzyskania oraz nielogiczne ze względu na budowę pojazdu. Ostatecznie zidentyfikowano 10 możliwych stanów pojazdu. W kolejnym kroku zidentyfikowano wszystkie możliwe przejścia pomiędzy stanami. Następnie określono warunki przejścia pomiędzy poszczególnymi stanami oraz błędy, które mogą wystąpić w układzie napędowym pojazdu. Ostatecznie decyzja o zmianie stanu następuje w zależności od aktualnego stanu pojazdu oraz wystąpienia określonych warunków i błędów. Strategia została opisana dla *HEV* o strukturze równoległej, jednak po pewnych modyfikacjach, może z powodzeniem zostać zastosowana w pojazdach *HEV* o innej konfiguracji. Innym podejściem jest podejście bazujące na częstotliwościach zmiany mocy. Polega ono na podziale zapotrzebowania na moc w pojeździe na komponent o wysokiej i niskiej częstotliwości. Zapotrzebowanie na moc jest realizowane oddzielnie dla tych komponentów. Podejście takie cechuje się wyższą sprawnością w stosunku do najprostszej strategii termostatu [7]. Innym sposobem jest korzystanie z map sprawności silników i odpowiedni wybór jednostki napędowej w przypadku pojazdów *HEV* o konfiguracji równoległej. Podejście może wykorzystywać optymalne punkty pracy, linię pracy silnika, jak i mapę sprawności. Takie podejście wykorzystano tworząc

strategię sterowania dla pojazdu *HEV* o konfiguracji szeregowo-równoległej [32]. Podział mocy pojazdu pomiędzy napęd równoległy i szeregowy następował w taki sposób, by sprawność całego układu napędowego była jak najwyższa. Układ sterowania korzystał w tym wypadku z predefiniowanej mapy sprawności, utworzonej na podstawie mapy sprawności poszczególnych elementów układu napędowego. Zaletą powyższych metod jest łatwość implementacji w rzeczywistym pojeździe. Strategie te nie wymagają dużej ilości obliczeń i są relatywnie proste. Ich skuteczność zależy jednak w dużym stopniu od doświadczenia projektantów. Dodatkowo strategie deterministyczne są stałe, przez co nie adoptują się do zmieniających się warunków jazdy. Pewną próbą odpowiedzi na ten problem była próba zastosowania strategii opartych na deterministycznych regułach, w połączeniu z rozpoznawaniem wzorców jazdy [8]. Pozwalała ona na stosowanie różnych zastawów reguł w zależności od warunków jazdy. Rozpoznawanie wzorców jazdy (*ang. DPR, driving pattern recognition*) zostało szerzej opisane w dalszej części niniejszej rozprawy doktorskiej.

Algorytmy wykorzystujące logikę rozmytą (*ang. fuzzy logic*) stanowią osobną i bardziej zaawansowaną grupę strategii z wykorzystaniem reguł. Bazują one na strategiach z wykorzystaniem reguł. Podstawową ideą strategii w tej grupie jest zastosowanie reguł w postaci JEŻELI-TO, bazującej na wiedzy eksperckiej i doświadczeniu projektantów. Głównymi zaletami strategii opartych na logice rozmytej jest odporność na zakłócenia oraz łatwa adaptowalność. Ponieważ w logice rozmytej wykorzystywane są zmienne lingwistyczne, w przypadku tego typu strategii nie jest konieczna budowa skomplikowanego modelu matematycznego pojazdu [7]. Z tego powodu tego typu strategie nadają się bardzo dobrze do zarządzania energią w wielodomenowym, nieliniowym, zmiennym w czasie systemie jakim jest *HEV*. Logika rozmyta została wykorzystana jako pierwsza, do zarządzania energią w pojazdach *HEV* o strukturze równoległej przez Baumanna i innych [33] oraz Lee i innych [34] już w 1998 roku. W późniejszym czasie strategie bazujące na logice rozmytej zostały wprowadzone do *HEV* o strukturze szeregowej [35] i szeregowo-równoległej [36]. W każdym algorytmie bazującym na logice rozmytej można wyróżnić zasadniczo 4 podstawowe etapy. Należą do nich: rozmywanie (*ang. fuzzification*), wyznaczenie stopnia aktywacji reguł, modyfikacja stopnia konkluzji reguł oraz wyostrzanie (*ang. defuzzification*). W pierwszym etapie następuje zamiana danych ilościowych na stopień przynależności do zbiorów jakościowych (np. niski poziom napięcia), wraz z określonym stopniem przynależności do tego zbioru. W drugim etapie następuje określenie stopnia w jakim dane reguły są przydatne. Zależy to od stopnia spełnienia przesłanki w regule. Następnie reguły, które są w danym momencie aktywne zostają połączone w jedną regułę - konkluzję reguł. Konkluzja jest zbiorem rozmytym, któremu można nadać znaczenie lingwistyczne. W następnym etapie powstały zbiór rozmyty zostaje poddany wyostrzaniu, którego wynikiem jest konkretna wartość liczbowa zmiennej sterującej [37]. Istnieje wiele możliwych do zastosowania strategii wykorzystujących logikę rozmytą. Większość z nich opiera się na innych, opisanych powyżej strategiach bazujących na wykorzystaniu reguł, takich jak strategia termostatu czy śledzenia mocy [6]. Istnieje także możliwość wykorzystania różnych algorytmów z innych grup, w tym bazujących na optymalizacji i połączenie ich w jeden

algorytm z wykorzystaniem logiki rozmytej. Jednym z konwencjonalnych podejść do wykorzystania logiki rozmytej było wykorzystanie jej do opracowania sterownika składającego się z interpretatora intencji kierowcy oraz kontrolera balansu mocy. Pierwszy blok odpowiadał za zamianę intencji kierowcy, sygnalizowanej poprzez pedał przyspieszenia i hamulca, na wartość liczbową odpowiadającą za stopień zmiany prędkości pojazdu. Następnie drugi blok zamieniał ten sygnał na optymalny moment napędowy silnika, stosownie do aktualnych parametrów ruchu pojazdu [38]. Innym podejściem jest wykorzystanie logiki rozmytej do zarządzania podziałem momentu obrotowego dla *HEV* o strukturze równoległej w zależności od obciążenia oraz *SOC* akumulatorów pojazdu [39-40]. Oprócz podejść bardziej klasycznych, zostały opisane podejścia wykorzystujące inne metody sztucznej inteligencji [41]. Ponieważ w klasycznym podejściu o kształcie zbiorów rozmytych i wartości innych parametrów algorytmu decyduje człowiek, nie można zagwarantować ich optymalnego wyboru. Z tego powodu w wielu przypadkach, strojenie parametrów dla logiki rozmytej odbywa się z wykorzystaniem metod optymalizacji, takich jak algorytmy genetyczne [42], czy rojowe [43].

Strategie oparte na optymalizacji stanowią osobną dużą grupę. Jako pierwsze wykształciły się strategie oparte na optymalizacji offline. W strategiach tych wykorzystuje się historyczne zapisy zapotrzebowania na moc w pojeździe lub historyczne profile prędkości, do określenia minimum energii potrzebnej do pokonania trasy oraz sposobu w jaki takie minimum jest możliwe do osiągnięcia. Można wśród nich wyróżnić algorytmy oparte na gradiencie oraz metody bezgradientowe. Metody gradientowe są łatwe w implementacji, jednak ich wadą jest wrażliwość na minima lokalne. Dodatkowo funkcje, które podlegają optymalizacji, muszą spełniać szereg dodatkowych kryteriów, takich jak: ciągłość, różniczkowalność itd. System *HEV* jest systemem nieliniowym z licznymi zakłóceniami. Z tego powodu strategie te są rzadko stosowane [7].

Metody bezgradientowe stanowią zdecydowanie istotniejszą grupę strategii z punktu widzenia *HEV*. Metody bezgradientowe nie opierają się na różniczkach funkcji, zamiast tego bazując na iteracyjnych obliczeniach. Wśród wykorzystywanych metod można wyróżnić algorytm sympleksowy [44-45] oraz metody przeszukiwania stochastycznego. To właśnie te metody są najczęściej wykorzystywane do poszukiwania optymalnego sposobu zarządzania mocą w *HEV*. Obejmują one takie algorytmy jak: algorytmy genetyczne GA [46], algorytm symulowanego wyżarzania SA [47], algorytmy rojowe PSO [48]. Spośród wymienionych metod, w pracach naukowych najczęściej spotkać można podejście związane z algorytmem genetycznym [7]. Jego zaletą jest duża uniwersalność, możliwość znajdowania minimum globalnego w przestrzeniach o różnych kształtach oraz duża skuteczność w znajdowaniu minimum globalnego. Niestety czas uzyskania wyniku silnie zależy od wylosowanej populacji początkowej.

Dynamiczne metody optymalizacji mogą zostać podzielone na metody pośrednie i bezpośrednie. Metody pośrednie opierają się na teorii sterowania optymalnego. Możemy zaliczyć do nich: programowanie dynamiczne (*DP*) oraz zasadę maksimum Pontriagina (*PMP*) [7]. Obydwie

metody znalazły szerokie zastosowanie dla optymalizacji zarządzania energią w pojazdach typu *HEV*. Programowanie dynamiczne zostanie szerzej omówione w kolejnych rozdziałach niniejszej rozprawy doktorskiej.

Zasada minimum Pontriagina (*PMP*) opiera się na teorii sterowania optymalnego i stanowi rozszerzenie rachunku wariacyjnego. W metodzie tej globalny problem optymalizacji o znanych ograniczeniach zostaje sprowadzony do lokalnego problemu optymalizacji opisanego przez równania Hamiltona. W rezultacie metoda *PMP* może teoretycznie zostać zastosowana w czasie rzeczywistym przy mniejszym obciążeniu obliczeniowym niż programowanie dynamiczne [7]. *PMP* została po raz pierwszy zastosowana w tematyce *HEV* w 2001 roku [49]. Zastosowano tam metodę *PMP* do optymalizacji podziału mocy pomiędzy silnik elektryczny i spalinowy w pojeździe *HEV* o strukturze równoległej. Jak wykazały dalsze badania, metoda *PMP* jako rezultat daje jedynie warunki niezbędne dla rozwiązania optymalnego. W przypadku posiadania dodatkowych informacji o zachowaniu systemu, rozwiązanie otrzymane w wyniku zastosowania metody *PMP* może być rozwiązaniem optymalnym [50]. Aby rozwiązanie było optymalne w całym zakresie czasu, konieczne jest zdefiniowanie optymalnych stanów sterowania (*ang. co-state*) określonych przez zmienne sterujące. Zaletą metody *PMP* jest fakt, że, początkowy zestaw zmiennych sterujących jest pojedynczym parametrem, dla pojedynczego profilu prędkości pojazdu. Optymalne wartości zmiennych sterujących mogą zostać dobrane iteracyjnie, na przykład z użyciem algorytmu przeszukiwania dychotomicznego [51]. Aby było to możliwe konieczna jest znajomość przyszłej prędkości pojazdu oraz warunków jazdy. W rzeczywistych warunkach, dokładna i pełna znajomość przyszłych warunków jazdy oraz prędkości pojazdu jest niemożliwa do uzyskania. Dodatkowo zestaw początkowych zmiennych sterujących jest specyficzny dla danego profilu prędkości i ich wartości różnią się dla różnych profili prędkości. Nie mogą być one określone z góry dla nieznanego profilu prędkości. Powyższa wada metody bardzo utrudnia i ogranicza wykorzystanie metody *PMP* do optymalnego zarządzania energią, w pojeździe w czasie rzeczywistym. Powstało wiele prac mających na celu przezwycięzenie tych trudności. Jeden z pierwszych pomysłów wykorzystywał fakt bliskiego związku pomiędzy początkowymi wartościami zmiennych sterujących a zmiennymi określającymi stan akumulatora. W podejściu tym początkowe wartości zmiennych sterujących były korygowane w oparciu o pętle sprzężenia zwrotnego pomiędzy aktualnym stanem baterii a stanem referencyjnym. Referencyjny stan baterii określany był na podstawie przeszłych, przyszłych i aktualnych informacji o warunkach jazdy. Pętla sprzężenia zwrotnego może być proporcjonalna (*P*) [52], proporcjonalno-całkująca (*PI*) [53], proporcjonalno-całkująco-różniczkująca (*PID*) [54] lub nieliniowa [55]. Podejście to sprawdzało się dobrze, przy spełnieniu warunku, że informacje referencyjne na temat stanu baterii pochodziły z przyszłości. Z tego powodu powyższą strategię zaczęto łączyć z innymi metodami, takimi jak: przewidywanie cyklu jazdy [56] lub rozpoznawanie wzorców jazdy (*DPR*) [57]. Ze względu na wymaganą moc obliczeniową, aby możliwe było wykorzystanie algorytmu *PMP* do wykorzystania w czasie rzeczywistym, korzysta się z wcześniej obliczonych tablic [58]. Ponieważ rozmiar zajmowany przez tablice w pamięci rośnie wykładniczo wraz

ze wzrostem ich wymiarów, zaproponowano przybliżony algorytm *PMP* [59]. W metodzie tej, bazując na fragmentarycznej aproksymacji spalania paliwa przez silnik, problem chwilowej optymalizacji z wykorzystaniem równań Hamiltona zostaje sprowadzony do problemu optymalizacji funkcji wypukłej, który może zostać zaimplementowany w pojeździe.

Metody bezpośrednie stanowią drugą podgrupę dynamicznych metod optymalizacji. W metodach bezpośrednich, aproksymuje się problem optymalnego sterowania do problemu statycznej optymalizacji, poprzez dyskretyzację. Przybliżone rozwiązanie w dziedzinie optymalnego sterowania może więc być uzyskane poprzez rozwiązanie statycznej optymalizacji. W metodach tych możemy mieć do czynienia z dyskretyzacją tylko zmiennych sterujących lub z dyskretyzacją zarówno zmiennych sterujących jak i zmiennych stanu. W przypadku dyskretyzacji jedynie zmiennych sterujących mówimy o metodzie parametryzacji zmiennych sterujących. W sytuacji gdy dyskretyzacji podlegają zarówno zmienne sterujące jak i zmienne stanu, mówimy o metodach bezpośredniej kolokacji [7]. W przypadku dyskretyzacji jedynie zmiennych sterujących konieczne jest zastosowanie nierówności dla warunków brzegowych, co powoduje liczne problemy i komplikacje. Z tego powodu do rozwiązywania problemu optymalnego zarządzania energią w *HEV* wykorzystuje się jedynie metody bezpośredniej kolokacji [60]. Dokładność wyniku w przypadku metod bezpośredniej kolokacji silnie zależy od stopnia dyskretyzacji funkcji bazowych. Niewielkie zwiększenie dokładności może skutkować znacznym zwiększeniem ilości obliczeń do wykonania. By przezwyciężyć te trudności zaproponowano ulepszoną metodę bezpośredniej kolokacji, opartą na wielomianach ortogonalnych. Pozwala ona na zwiększenie dokładności obliczeń, przy ograniczonej ilości dodatkowych punktów [61].

Inne metody optymalizacji offline - obejmują takie metody, jak: nieliniowe sterowanie optymalne [62], sterowanie stochastyczne [63] oraz algorytm oparty na teorii gier [64]. Metody te nie zdobyły dużej popularności i nie były przedmiotem intensywnych badań. Spośród wymienionych metod najciekawsza wydaje się metoda oparta na teorii gier. Teoria gier została opracowana w dziedzinie ekonomii, a później znalazła zastosowanie także w innych dziedzinach. W opisywanym przypadku zarządzanie energią w pojeździe *HEV* traktowane jest jak niekooperacyjna gra pomiędzy kierowcą i układem napędowym [64]. Podejście to, choć bardzo ciekawe, nie okazało się wystarczająco skuteczne [7].

Strategie bazujące na optymalizacji online, w przeciwieństwie do strategii bazujących na globalnych optymalizacjach, mogą zostać zastosowane bezpośrednio w pojeździe. Muszą być one wystarczająco proste obliczeniowo by możliwe było szybkie uzyskanie wyniku przy jednoczesnych ograniczeniach sprzętowych, dotyczących mocy obliczeniowej. Z tych powodów dają one gorsze rezultaty niż algorytmy globalnej optymalizacji zastosowane do tych samych metod. Najczęstszym celem ich stosowania jest ograniczenie zużycia energii w pojeździe, przy czym, aby było to możliwe, konieczne jest przeliczenie energii elektrycznej bądź zużywanego paliwa na jednakowe jednostki [7]. Do podstawowych grup metod zaliczyć można: sterowanie odporne, sterowanie inteligentne, regulatory

poszukujące ekstremum, *ECMS* oraz *MPC*. Strategie oparte o *MPC* zostały omówione szerzej w kolejnych rozdziałach rozprawy.

Sterowanie odporne jest rodzajem sterowania ze sprzężeniem zwrotnym, o parametrach dobranych w taki sposób, że parametry sygnału dla układu zamkniętego znajdują się w wyznaczonych przedziałach. Powyższa definicja obejmuje takie wymagania, jak odporność na zakłócenia czy zdolność do ich odrzucania. Dodatkowo sterowanie odporne jest odpowiednie dla modeli dynamicznych. Z tych powodów sterowanie to może być z powodzeniem zastosowane do zarządzania energią w nieliniowym, zmiennym w czasie systemie *HEV*, a dodatkowo umożliwia zastosowanie w rzeczywistym pojeździe [8]. W literaturze opisano kilka udanych przykładów zastosowania systemów odpornych do zarządzania energią *HEV* [65-67]. Uzyskano wyniki, które dawały wartości suboptymalne, podobnie jak inne strategie online. Jednakże sterowanie odporne wymaga dużego nakładu pracy związanego z przekształceniami równań matematycznych opisujących system. Złożoność matematyczna oraz prostota przekształcenia układów nieliniowych zmiennych w czasie do układów liniowych niezależnych od czasu, sprawiły, że rozwój sterowania odpornego w dziedzinie zarządzania energią w pojazdach *HEV* został zahamowany.[7]

Regulatory poszukujące ekstremum (ang. *ES, extremum-seeking*), należą do grupy adaptacyjnych algorytmów sterowania, które w sposób dynamiczny znajdują optymalny punkt pracy systemu. Algorytmy *ES* nie opierają się przy tym na dokładnym modelu systemu, który jest obiektem sterowania. Nadają się one doskonale do sterowania nieliniowego, dynamicznego systemu, takiego jak *HEV*, również w czasie rzeczywistym. Algorytm ten został zaproponowany po raz pierwszy przez Dicmana w 2010 roku do optymalizacji pracy pojazdu *HEV* o konfiguracji równoległej [68]. Rozwiązanie otrzymane dzięki algorytmowi jest rozwiązaniem optymalnym, ale tylko lokalnie. W celu ulepszenia algorytmu i otrzymania lepszych wyników połączono algorytm *ES* z metodą programowania pół-określonego (ang. *SDP, semidefinite programming*) [69]. W artykule wykorzystano metodę *SDP* do zapewnienia globalnej optymalności rozwiązania oraz zapewnienia zrównoważenia poziomu naładowania akumulatorów. Z kolei algorytm *ES* został wykorzystany do poszukiwania dokładnego lokalnego optimum w czasie rzeczywistym. Algorytmy z podgrupy *ES* mają potencjał by zostać zaimplementowane do optymalizacji online w czasie rzeczywistym w pojazdach *HEV*. Badania nad tego typu systemem zarządzającym energią w pojeździe *HEV*, ograniczają się jednak ciągle jedynie do symulacji [7].

Sterowanie inteligentne wykorzystuje różne metody uczenia maszynowego do podejmowania decyzji dotyczących zarządzania energią w pojeździe *HEV*. Wykorzystywane są różne metody uczenia maszynowego, w tym: sieci neuronowe (ang. *NN, neural network*) [41], sieci neuronowe Elmana (ang. *ENN, Elman neural network*) [70], maszyny wektorów wspierających (ang. *SVM support vector machine*), rekurencyjne metody *NK* (ang. *RLS, recursive least square*)[71] oraz inne [72]. Zaletą algorytmów wykorzystujących uczenie maszynowe jest brak konieczności budowania skomplikowanych modeli układu napędowego pojazdu. Do uczenia maszynowego konieczne są bazy

danych, posiadające liczne, poprawne i pokrywające pełne spektrum możliwości, przypadki. Budowa odpowiednich baz danych jest trudna i czasochłonna. Jednocześnie wpływają one bezpośrednio na dokładność uzyskiwanych wyników [7]. Algorytmy uczenia maszynowego pod warunkiem dysponowania poprawnymi bazami danych, obejmującymi wystarczającą ilość przypadków, bardzo dobrze nadają się do zastosowania w czasie rzeczywistym. Podstawowym czynnikiem jest, w tym przypadku mała wymagana moc obliczeniowa, w sytuacji posiadania wcześniej wyuczonego modelu.

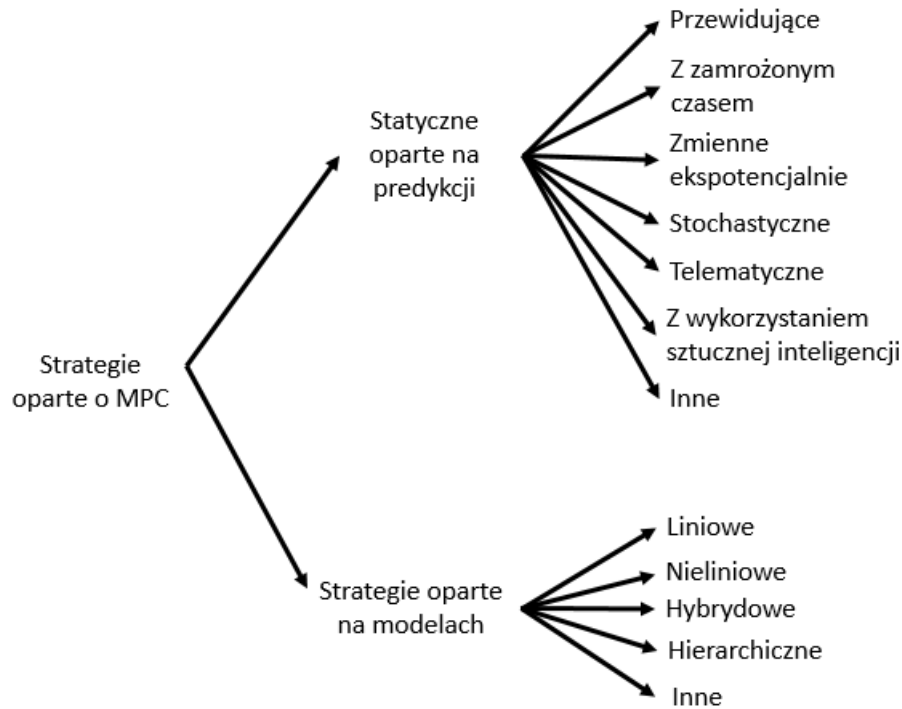
Strategia ECMS (ang. *ECMS- equivalent consumption minimization strategy*) została zaproponowana przez Paganelli [73] w 2000 roku i od tego czasu była przedmiotem badań wielu naukowców. Głównym celem strategii jest zamiana problemu globalnej optymalizacji na serię optymalizacji lokalnych, rozwiązywanych krok po kroku. W strategii zakłada się, że na całkowitą ilość paliwa zużytego przez pojazd składa się paliwo zużyte przez silnik spalinowy oraz energia elektryczna wykorzystana przez silnik elektryczny, przeliczona za pomocą specjalnego ekwiwalentu, podobnie jak ma to miejsce w metodzie *PMP*. Jako przybliżona realizacja *PMP*, *ECMS* może być wykorzystany do optymalizacji zużycia energii w pojeździe w czasie rzeczywistym [7]. Sposób wyznaczania tego ekwiwalentu może być bardzo różny i stanowi główną oś badań nad strategią *ECMS*. Uwzględniały one zarówno sposób obliczania ekwiwalentu paliw, jak i jego wpływ na wyniki. Na sposób obliczenia ekwiwalentu wpływ mają takie czynniki, jak: profil prędkości pojazdu, limity ładowania i rozładowania baterii czy kierunek przepływu prądu, który z reguły jest nieprzewidywalny. Obliczanie ekwiwalentu paliwa można podzielić na dwie główne grupy [7]. W przypadku pierwszej, przyjmuje się, że ekwiwalent jest stały i nie zmienia się dla danego cyklu jazdy. Może on zostać obliczony na podstawie: średniej wartości konwersji pomiędzy paliwem a energią elektryczną [74], metody strzałów [75], oraz na podstawie globalnych metod optymalizacji. Do wykorzystywanych globalnych metod optymalizacji zaliczyć można programowanie dynamiczne [76], algorytmy genetyczne [26] i algorytmy rojowe [77]. Metody te są bardzo dobrze poznane i stosunkowo proste. Są one stosowane z sukcesem. Wymagają one jednak znajomości profilu prędkości i zapotrzebowania na energię w pojeździe, z wyprzedzeniem. Ekwiwalent paliwa musi także zostać ponownie obliczony i skalibrowany dla każdego profilu prędkości. Ogranicza to znacznie zastosowanie strategii *ECMS* oraz uniemożliwia jej wykorzystanie w czasie rzeczywistym. W drugiej grupie metod obliczanie ekwiwalentu paliwa odbywa się online. Grupa ta może także zostać podzielona na 3 osobne podgrupy [7]. W przypadku pierwszej z 3 podgrup, podczas obliczeń brane są pod uwagę limity ładowania i rozładowania baterii oraz stopnia jej naładowania (*SOC*). Wykorzystuje się w nich podobieństwo pomiędzy stanem zmiennych sterujących i ekwiwalentem paliwa. Ekwiwalent paliwa może być obliczany jako stały współczynnik, obliczany na podstawie wcześniej przeprowadzonej optymalizacji offline oraz współczynnika korekcyjnego. Współczynnik korekcyjny może być obliczany na podstawie stopnia naładowania akumulatorów (*SOC*), z wykorzystaniem sterowania proporcjonalnego [27], proporcjonalno-całkującego [78], lub innego nieliniowego sterowania z pętlą sprzężenia zwrotnego [79]. Wadą przedstawionego rozwiązania jest silna zależność optymalnej wartości ekwiwalentu od profilu prędkości pojazdu. W przypadku drugiej

kategorii algorytmów pod uwagę brane są zarówno limity rozładowania i ładowania akumulatorów oraz *SOC* akumulatorów, jak i kierunek przepływu prądu. Można wyróżnić tu podejście, w którym ekwiwalent paliwa był obliczany na podstawie *SOC* akumulatorów oraz jej pochodnej [80]. Innym podejściem jest obliczanie dwóch ekwiwalentów paliwa - dla rozładowywania i ładowania akumulatorów. Następnie określa się prawdopodobieństwo określające aktualne i przyszłe zużycie energii [81]. Trzecią podkategorię stanowią metody wykorzystujące zarówno informacje o *SOC* akumulatora, jak i profilu prędkości pojazdu. Ze względu na to, że profil prędkości pojazdu nie może być w pełni znany w trakcie przejazdu, strategie z tej podgrupy wykorzystują różne niepełne informacje. Może zaliczać się do nich: 1) pozycja pojazdu i stopień naładowania akumulatorów [82], 2) *SOC* akumulatorów, pozycja pojazdu, nachylenie terenu i średnia prędkość pojazdu [83], 3) *SOC* akumulatorów, czas przejazdu oraz zmiana nachylenia terenu [84], 4) stopień naładowania akumulatorów, przeszła i przewidywana pozycja pojazdu i pozycja *GPS* [85]. Wadą powyższych rozwiązań są wysokie wymagania dotyczące mocy obliczeniowej oraz występujące błędy predykcji [7]. Innym podejściem jest wykorzystywanie rozpoznawania wzorców jazdy (*ang. DRP*), na podstawie, którego wartość ekwiwalentu paliwa zostaje zaktualizowana [86]. Skuteczność poszczególnych metod oraz wpływ poszczególnych parametrów na wyniki podlega stałemu rozwojowi i badaniom.

2.4 Algorytmy wykorzystujące sterowanie predykcyjne

Sterowanie predykcyjne (*ang. MPC - Model Predictive Control*) polega na dostosowywaniu działania regulatora z wyprzedzeniem. Aby było to możliwe, regulator musi przewidywać stan środka technicznego z wyprzedzeniem. Tego typu sterowanie powstało w latach 60-tych XX wieku i początkowo wykorzystywane było w przemyśle chemicznym. Podyktowane to było małą mocą obliczeniową ówczesnych maszyn liczących i komputerów. W przemyśle chemicznym procesy następowały na tyle wolno, że możliwe było zastosowanie sterowania predykcyjnego [8]. Obecnie jest ono szeroko wykorzystywane w przypadku zarządzania energią w pojazdach *HEV*. Działanie *MPC* można opisać w trzech podstawowych krokach. Na początku następuje predykcja zachowania obiektu sterowania w określonym horyzoncie czasowym. W drugim kroku następuje wyliczenie optymalnej sekwencji sygnałów sterujących. W trzecim kroku natomiast następuje wykonanie pierwszej części sygnałów sterujących w rzeczywistym obiekcie, a następnie przesunięcie horyzontu dokonywanej predykcji o jedną jednostkę czasu. W końcu proces powtarza się od pierwszego punktu [7]. Wynika stąd, że *MPC* w przeciwieństwie do opisanych w poprzednim rozdziale strategii optymalizacyjnych, jest strategią bazującą na optymalizacji ograniczonego horyzontu czasowego. Pozwala to znacznie zmniejszyć wysiłek obliczeniowy potrzebny do optymalizacji. Jednakże opisane w poprzednim rozdziale strategie mogą zostać wykorzystane do optymalizacji strategii w *MPC*, w ramach określonego horyzontu czasowego.

Kluczowym elementem strategii opartych na sterowaniu predykcyjnym jest sposób, w jaki algorytm przewiduje przyszłe zapotrzebowanie na energię w pojeździe. Z tego powodu strategie bazujące na *MPC*, które są wykorzystywane do zarządzania energią w *HEV*, można podzielić na dwie podstawowe podgrupy. Są to strategie oparte na predykcji i strategie oparte na modelach. Szczegółowy podział strategii w ramach *MPC* został przedstawiony na Rys. 9.



Rys. 9. Podział metod zarządzania energią wykorzystujących *MPC* w *HEV* [8]

W przypadku metod opartych na predykcji nie występuje żaden model predykcyjny i przewidywane zapotrzebowanie na energię w pojeździe otrzymuje się za pomocą innych metod. Można zaliczyć do nich strategie przewidujące, strategie z zamrożonym czasem, zmienne ekspotencjalnie, strategie stochastyczne, strategie oparte o telematykę, wykorzystujące algorytmy sztucznej inteligencji oraz inne, oparte na przykład na statystyce.

Strategia z zamrożonym czasem jest najprostszą możliwą strategią, bardzo łatwą w implementacji. Bazuje ona na założeniu, że zapotrzebowanie na energię w całym przewidywanym horyzoncie czasowym jest stałe i równe aktualnemu zapotrzebowaniu na energię w pojeździe. Strategia ta nie przynosi dobrych rezultatów i często bywa punktem odniesienia w stosunku do innych strategii [8]. Przykładem może być [87], gdzie porównano wyniki osiągnięte za pomocą stochastycznej strategii *MPC*, z wynikami osiąganymi za pomocą strategii *MPC* z zamrożonym czasem i osiągnięto względem niej znaczną poprawę wyników.

Strategia przewidująca zakłada pełną i dokładną znajomość przyszłych warunków jazdy. Strategia ta nie jest możliwa do realizacji w żadnym pojeździe, gdyż w rzeczywistości taka znajomość warunków trasy nie jest możliwa. Może ona jednak służyć jako dobre odniesienie wobec innych strategii, podobnie, jak ma to miejsce w przypadku strategii z zamrożonym czasem. W przypadku strategii z zamrożonym czasem, należy oczekiwać znacznej poprawy rezultatów. W przypadku strategii przewidującej należy oczekiwać, że wyniki innych strategii będą gorsze, jednak powinny one zbliżyć się do wyniku osiąganego przez strategię przewidującą. Strategia ta zakłada pełną znajomość warunków panujących na trasie oraz prędkości pojazdu, jednak cały czas działa ona w oparciu o ogólną zasadę strategii MPC. Oznacza to, że optymalizacja nadal zachodzi jedynie w ramach przewidzianego horyzontu czasowego. Z tego powodu otrzymany wynik jest wynikiem suboptymalnym. Można jednak wykazać, że wyniki te mogą być bardzo zbliżone do rozwiązania optymalnego w skali globalnej i wynosić nawet 96% wyników w stosunku do rozwiązania optymalnego globalnie [8]. Przykłady badań, w których jako punkt odniesienia przyjęto strategię przewidującą można znaleźć w [88-91].

W strategiach zmiennych eksponentalnie zakłada się, że informacje o przyszłych warunkach jazdy mogą być opisane przez prostą zależność eksponentalną w ramach przewidywanego horyzontu czasowego. Podczas tworzenia strategii zakłada się, że wymagany moment napędowy będzie malał eksponentalnie w czasie, zgodnie z zależnością [8]:

$$T_d(k+1) = T_d(k) * e^{\left(\frac{-t_s}{t_d}\right)} \quad i = 1, 2, \dots, N \quad (5)$$

Gdzie: $T_d(k)$ oznacza wymagany moment napędowy w określonej chwili, N oznacza długość predykcji, $T_d(k+1)$ jest wymaganym momentem napędowym w konkretnej długości predykcji, t_s jest czasem próbkowania, zaś t_d jest parametrem określającym szybkość zaniku. Równanie to może zostać zamienione na równanie opisujące predykcję prędkości pojazdu [8]:

$$V(k+1) = V(k) * (1 + \varepsilon)^i \quad i = 1, 2, \dots, N \quad (6)$$

Gdzie: $V(k+1)$ oznacza przewidywaną prędkość pojazdu w kolejnym kroku, $V(k)$ - aktualną prędkość pojazdu, N - długość horyzontu czasowego, dla którego przygotowana jest predykcja, zaś ε odnosi się do współczynnika wykładniczego. Metoda ta jest wrażliwa na wartości współczynnika wykładniczego. Optymalna wartość współczynnika może bardzo się różnić, w zależności od profilu prędkości pojazdu. Pomimo to, zaproponowana metoda może przynosić dobre rezultaty poprawiające efektywne wykorzystanie energii w pojeździe [11]. Wpływ współczynnika wykładniczego na dokładność predykcji została opisana w [92]. Największą zaletą tej strategii jest niski nakład obliczeniowy oraz prostota implementacji.

Stochastyczne metody MPC opierają się na łańcuchach Markova. Łańcuchy Markova, nazywane też stochastycznym programowaniem dynamicznym, wykorzystywane są do rozwiązywania

dynamicznych problemów decyzyjnych z wieloma okresami pomiędzy decyzjami w przestrzeni stochastycznej [93]. Przez dynamiczne problemy decyzyjne rozumie się problemy, w których aktualne decyzje skutkują zmianą przyszłych stanów systemu, mających wpływ na przyszłe decyzje. Proces optymalnego zarządzania energią w pojeździe *HEV* również może być rozpatrywany w ten sposób. Ponieważ łańcuchy Markova okazały się obiecujące i ważne w zakresie prognozowania przyszłego zapotrzebowania na moc przez kierowcę oraz do predykcji prędkości pojazdu, zaczęły być one często stosowane do zarządzania energią w pojazdach *HEV*. Potencjał wykorzystania łańcuchów Markova w predykcyjnym sterowaniu energią w pojeździe *HEV* został zbadany w [94]. Osiągnięto rezultat gorszy jedynie o 0,3% od najniższej możliwej konsumpcji energii na badanej trasie. Stochastyczne sterowanie predykcyjne zostało wykorzystane w [95] do prognozowania przyszłego zachowania kierowcy. Zaproponowana strategia pozwalała ograniczyć spalanie paliwa oraz ilość wyemitowanego CO₂ dla pojazdu *HEV* o konfiguracji równoległej. Predykcję prędkości pojazdu na podstawie prawdopodobieństwa wystąpienia poszczególnych składowych profili prędkości wykonano w [96], dla pojazdu *HEV* o konfiguracji szeregowo- równoległej. Co ciekawe, pod uwagę wzięto również stosunek ceny energii elektrycznej do ceny paliwa. Wykazano, że stosunek ten może mieć bardzo istotny wpływ na uzyskiwane wyniki oraz, że w przyszłości powinien on zostać uwzględniony i aktualizowany podczas eksploatacji pojazdu. W [94], autorzy wykorzystywali informację z sygnału *GPS* oraz aktualne informacje o natężeniu ruchu drogowego. Informacje te nie były wykorzystywane do bardzo dokładnej predykcji prędkości pojazdu, a jedynie w sposób ogólny obrazowały trend, odnosząc się do ogólnej topografii terenu oraz ogólnych informacji o warunkach drogowych panujących na trasie. Bardzo ciekawe podejście można znaleźć w [97]. W artykule tym opisano strategię zarządzania energią w autobusie elektrycznym *HEV* o architekturze szeregowej typu plug-in. Co istotne, autobus ten poruszał się po stałych trasach, zgodnie z rozkładem jazdy. Powodowało to, że warunki panujące na trasie były bardzo powtarzalne. W strategii wykorzystano początkowo rozpoznawanie wzorców jazdy, na podstawie, których dokonywano następnie predykcji prędkości autobusu z wykorzystaniem łańcuchów Markova. Wyniki sztucznych profili prędkości pojazdu oraz profili rzeczywistych były bardzo zbliżone. Zupełnie odmienne podejście zostało opisane w [98]. Założono tam, że przyszła prędkość pojazdu zależy tylko i wyłącznie od aktualnej prędkości pojazdu i nie brano pod uwagę informacji z poprzednich stanów pojazdu lub danych historycznych. Uzyskano rezultaty zbliżone do wyników uzyskanych w przypadku programowania dynamicznego.

Oprócz łańcuchów Markova opisano wykorzystanie także innych stochastycznych podejść do zarządzania energią w pojeździe *HEV*, w oparciu o sterowanie predykcyjne. Przykładem może być podejście, w którym założono, że pojazd będzie się poruszał z prędkością zgodną z dwoma cyklami prędkości [99]. Następnie, na ich podstawie utworzono funkcję gęstości prawdopodobieństwa, opisującą prawdopodobieństwo przyszłej prędkości pojazdu w zależności od jego prędkości aktualnej. Uzyskane wyniki okazały się być zbliżone do wyników optymalnych przy pełnej znajomości profilu prędkości pojazdu. Innym interesującym przypadkiem jest wykorzystanie algorytmu K-najbliższych sąsiadów

[100]. Za pomocą metody K-najbliższych sąsiadów porównywano aktualny stan pojazdu ze stanami pojazdu w przeszłości i na tej podstawie starano się przewidywać prędkość pojazdu. Uzyskano bardzo dobre rezultaty. Zaletą tej strategii jest brak konieczności posiadania jakiegokolwiek wiedzy zarówno o samym pojeździe, jak i o trasie. Algorytm w całości bazuje na historycznych danych z eksploatacji pojazdu.

Strategie oparte na telematyce do predykcji zapotrzebowania na energię w pojeździe, wykorzystują nowe, dostępne rozwiązania telematyczne w sferze transportu, tzw. inteligentne systemy transportowe (*ang. ITS, intelligent transportation systems*). Można do nich zaliczyć pokładowy system *GPS*, system informacji geograficznej oraz zaawansowane techniki modelowania ruchu ulicznego [101]. Systemy te zapewniają dodatkowe informacje dotyczące aktualnej sytuacji drogowej oraz otoczenia pojazdu, rozumianego także bardzo szeroko. Informacje mogą pochodzić z innych pojazdów (*ang. V2V, vehicle-to-vehicle*), infrastruktury (*ang. V2I, vehicle-to-infrastructure*) oraz pokładowych czujników pojazdu [101]. Przykładem zastosowania może być układ do zarządzania energią w pojeździe *HEV* opisany w [83]. Zaproponowany algorytm składał się z dwóch algorytmów. Pierwszy z nich, o charakterze predykcyjnym, wykorzystywał informacje z pokładowego systemu nawigacji. Drugi, niepredykcyjny, korzystał z informacji dotyczących aktualnego stanu naładowania akumulatorów pojazdu (*SOC*). Informacje pozyskiwane z systemu nawigacji ograniczały się do danych o topografii terenu oraz średniej prędkości przejazdu na danych odcinkach trasy. Odnotowano wzrost sprawności pojazdu w stosunku do układu niewykorzystującego danych z pokładowej nawigacji pojazdu. Zaproponowana strategia została przygotowana dla pojazdu *HEV* o architekturze równoległej, jednak jak podkreślają autorzy, może ona zostać łatwo dostosowana do pojazdów *HEV* innych typów. Przykład wykorzystania informacji z systemu *GPS*, w połączeniu z historycznymi informacjami o zapotrzebowaniu pojazdu na energię przedstawiono w [102]. Strategia została zastosowana do zarządzania energią w autobusie typu *HEV*, który posiadał stałe trasy przejazdu. Informacje z systemu *GPS* przyczyniły się do zwiększenia precyzji predykcji prędkości autobusu i jego zapotrzebowania na energię. Autorzy podkreślają, że dzięki dodatkowym informacjom pochodzącym z innych czujników, możliwe jest dalsze zwiększenie precyzji predykcji zapotrzebowania na energię w pojeździe. Dokładniejszą analizę wpływu wykorzystywania różnych elementów *ITS* można znaleźć w [103]. Wykorzystanie aktualnych informacji o ruchu drogowym zaproponowano w [104]. Autorzy przeprowadzili badania nad strategią zarządzania energią w *PHEV*. Badania obejmowały strategię bez aktualnej informacji o ruchu drogowym, z uwzględnieniem statycznych informacji o ruchu drogowym oraz informacji aktualizowanych na bieżąco. W przypadku informacji o ruchu drogowym aktualizowanych na bieżąco, osiągnięto wzrost efektywności wykorzystania energii w pojeździe o 5% w stosunku do analogicznej trasy bez informacji o ruchu drogowym. Przykład wykorzystania danych pochodzących z innych pojazdów, do predykcji prędkości można znaleźć w [105]. Autorzy wykorzystali do predykcji prędkości pojazdu *HEV* o architekturze szeregowo-równoległej zarówno dane *V2V*, jak i *V2I*. Pozwoliło to na poprawę predykcji i niewielki wzrost

efektywności wykorzystania energii w pojeździe. Kompleksowe podejście zostało zaproponowane w [106]. Autorzy do predykcji prędkości w czasie rzeczywistym użyli danych pochodzących z systemów *GPS*, *V2V*, *V2I* oraz innych systemów *ITS*. W pracy szczególny nacisk położono na analizę błędów występujących podczas predykcji oraz wpływu zakłóceń na ich występowanie. Badania zostały przeprowadzone na podstawie rzeczywistych profili prędkości. Przedstawione we wspomnianych powyżej artykułach prace w przeważającej większości dotyczyły optymalnego zarządzania energią w pojazdach *HEV* poruszających się po stałych trasach. Wraz z zastosowaniem różnych inteligentnych systemów transportowych możliwe jest zwiększenie dokładności predykcji oraz zaplanowanie trasy z wyprzedzeniem także w innych przypadkach [8]. Przegląd dostępnych metod *ITS* oraz możliwości ich wykorzystania można znaleźć w [107].

Strategie wykorzystujące sztuczną inteligencję można podzielić na dwie podstawowe podgrupy. W pierwszej z nich następuje identyfikacja charakterystycznych parametrów, określających aktualny profil prędkości pojazdu lub jego części. Następnie na podstawie tych parametrów następuje przyporządkowanie danego profilu prędkości lub jego części do wcześniej zdefiniowanego, wzorcowego profilu prędkości pojazdu. W kolejnych krokach następuje dalsza predykcja prędkości pojazdu. Stanowią one algorytmy z grupy rozpoznawania wzorców jazdy (*ang. DPR, driving pattern recognition*). Szczegółowe omówienie metod *DPR* znajduje się w dalszej części niniejszej rozprawy doktorskiej. Druga grupa metod opiera się na założeniu, że aktualne i przyszłe warunki jazdy, takie jak prędkość pojazdu, są powiązane z przeszłymi warunkami jazdy. Z tego powodu do krótkookresowej predykcji prędkości pojazdu i warunków jazdy konieczna jest znajomość historycznych i aktualnych parametrów jazdy. Z oczywistych powodów dokładność predykcji silnie zależy od zmienności warunków. W przypadku gwałtownej zmiany warunków jazdy, skuteczność predykcji dramatycznie spada [8]. Tego typu podejście można znaleźć w [108]. Autorzy zaproponowali tam predykcyjny model wymaganej mocy pojazdu, z horyzontem czasowym wynoszącym 20 s. Do predykcji wykorzystano rekurencyjną sieć neuronową, której wejście stanowiło 15 parametrów pochodzących z historycznego profilu prędkości z dotychczas przejechanej trasy. W kolejnym kroku zużycie energii jest optymalizowane poprzez programowanie dynamiczne. Sieci neuronowe wykorzystano także w [109], gdzie za ich pomocą estymowano profile prędkości pojazdów. Ważną cechą badania był wybór pojazdów, które powinny mieć stałe trasy przejazdu, jednak mogły pokonywać ją z różnymi profilami prędkości. Badania zostały potwierdzone na rzeczywistych danych z 90% dokładnością. Innym przykładem wykorzystania algorytmów sztucznej inteligencji można znaleźć w [110], gdzie wykorzystano wnioskowanie Bayesowskie do poszukiwania korelacji pomiędzy aktualnym a historycznym profilem prędkości. Na tej podstawie wykonywano krótkookresową predykcję prędkości pojazdu. Uczenie przez wzmacnianie (*ang. reinforcement learning*) zostało zastosowane do dystrybucji momentu dla *HEV* o architekturze równoległej. [111]. W przedstawionym artykule zastosowano model przejścia oparty na łańcuchach Markova. Osiągnięto bardzo dobre wyniki, nieznacznie lepsze od stochastycznego programowania dynamicznego. Niezależnie od przyjętych metod sztucznej inteligencji

mają one niewątpliwie duży potencjał do predykcji zachowania nieliniowego, zmiennego systemu, jakim jest *HEV*. Z tego powodu możliwe jest zastosowanie innych metod sztucznej inteligencji, nie przedstawionych w niniejszym rozdziale, jak i modyfikacji metod przedstawionych [8].

Inne metody MPC, nie oparte na modelach, bazują najczęściej na parametrach statystycznych i prawdopodobieństwie występowania danej prędkości pojazdu. Przykładem może być [112], gdzie autorzy nie starają się przewidzieć profilu prędkości pojazdu jako zależności prędkości pojazdu od czasu, ale predykcji podlega dystrybucja prawdopodobieństwa występowania pewnych prędkości w określonym horyzoncie czasowym. W artykule [113] do predykcji prędkości użyto statycznej średniej prędkości pojazdu oraz odchylenia standardowego tej prędkości. Inni badacze starali się identyfikować styl jazdy kierowcy przez pomiar siły przykładowej do pedału gazu i następnie wykorzystując mieszany model Gaussa (*ang. Gaussian mixture model*).

Niezależnie od sposobu w jaki uzyskiwana jest predykcja prędkości pojazdu i warunków jazdy, strategie oparte na *MPC* uzyskują bardzo dobre wyniki, często zbliżone do wyników otrzymanych przez globalne metody optymalizacji.

Nieliniowe i liniowe MPC mogą opierać się na kilku rozwiązaniach. Układ napędowy *HEV* jest nieliniowy, zaś stany systemu jakim jest pojazd są ograniczone przez różne warunki. Ograniczenia dotyczą także wejść i wyjść systemu. Z tych powodów zadanie optymalnego zarządzania energią w pojeździe może zostać zmienione na problem optymalizacji nieliniowego systemu z ograniczeniami. Metody *MPC* bazujące bezpośrednio na nieliniowych modelach pojazdu są nieliniowe i wymagają nieliniowych solverów [8]. W literaturze można znaleźć wykorzystanie *MPC* w wersji jawnej (*ang. explicit*) [114-115]. W metodzie tej optymalne prawo kontroli jest obliczane offline i przechowywane w tabeli. Pozwala to na uzyskanie quasi-statycznego i możliwego do łatwego zaimplementowania prawa kontroli. Dzięki temu znacznie zmniejszono wymaganą moc obliczeniową i tym samym implementację *MPC* w czasie rzeczywistym. Jednakże należy zauważyć, że metoda ta jest silnie zależna od profilu prędkości pojazdu i w rzeczywistych warunkach, przy bardzo zmiennych warunkach pracy, nie będzie sprawdzać się dobrze. Dodatkowo sprawdza się ona dobrze jedynie przy małej ilości stanów, wejść i ograniczeń [116]. W praktyce problem rozwiązuje się zazwyczaj poprzez dyskretyzację i linearyzację modelu, które pozwalają na przekształcenie problemu *MPC* w programowanie kwadratowe, które może zostać rozwiązane za pomocą wielu algorytmów, wystarczająco szybkich, by można było je zastosować w czasie rzeczywistym [8].

Hybrydowe modele MPC powstają w wyniku dyskretyzacji części wejść lub zmiennych określających stan *HEV*. Może to dotyczyć ilości możliwych przełożeń, załączenia silnika spalinowego (silnik załączony lub wyłączony) lub też występującego bardzo często trybu jazdy (przykładowo tylko na silniku elektrycznym, podczas hamowania z odzyskiem, uruchomione oba silniki pojazdu itd.). Można wyróżnić wiele podejść do modelowania tego typu systemów, wliczając w to: dynamiczne systemy o mieszanej logice (*ang. MLD, mixed logical dynamical system*), *HYSDEL* (*ang. HYSDEL, hybrid systems description language*) oraz *PWA* (*ang. PWA, piecewise affine model*) [117].

Hierarchiczne strategie MPC posiadają logiczną i uporządkowaną strukturę. Zazwyczaj, w przypadku pojazdów *HEV*, to sterownik *MPC* jest nadrzędny i wyznacza parametry pracy dla innych komponentów systemu. Te komponenty mają swoje własne sterowniki, które pomagają im spełnić parametry pracy wyznaczone przez *MPC*. W podobny sposób może zostać zorganizowana struktura samego sterownika bądź algorytmu *MPC*. W takim przypadku górne poziomy struktury zarządzają pracą niższych poziomów struktury [118]. Przykładem może być kaskadowy algorytm *MPC* [119]. Górny poziom struktury odpowiadał w tym przypadku za utrzymanie odpowiedniego poziomu naładowania akumulatorów oraz za obliczanie wymaganej prędkości i momentu obrotowego na silniku. Dolny poziom struktury był odpowiedzialny za uzyskanie wymaganej prędkości obrotowej oraz momentu obrotowego silnika oraz uruchomienie zintegrowanego generatora. Innym przykładem hierarchicznej struktury może być algorytm opisany w [120]. W tym wypadku poszczególne fragmenty struktury algorytmu *MPC* były odpowiedzialne za optymalizację pracy pojazdu w różnych przedziałach czasu. Górny poziom był odpowiedzialny za zachowanie systemu w długiej skali czasu, reprezentując część systemu o mniejszej dynamice. Poziom dolny odpowiadał części systemu o mniejszej dynamice. Wartości referencyjne dla zmiennych stanu były obliczane przez górny poziom systemu i przesyłane do dolnego poziomu. Dolny poziom pracował na większej częstotliwości i odpowiadał za bezpośrednią pracę całego systemu. Decyzje podejmowane przez sterownik dolnego poziomu były bezpośrednio wykonywane przez poszczególne elementy pojazdu.

2.5 Rozpoznawanie wzorców jazdy

Rozpoznawanie wzorców jazdy (*ang. Driving Pattern Recognition, DPR*), formalnie, stanowi podgrupę algorytmów *MPC* [8]. Mianem tym określa się metody i algorytmy, których celem jest rozpoznanie wzorców i schematów, występujących podczas przejazdu pojazdem. Do wzorców takich najczęściej zalicza się ogólny typ ruchu pojazdu, z jakim mamy do czynienia [121]. Może to być przykładowo jazda w ruchu miejskim, przy zakorkowanych ulicach, podczas godzin szczytu, przejazd autostradą lub przejazd przez miasto w warunkach umiarkowanego ruchu. Dokładna liczba ogólnych typów ruchu zależy od konkretnego autora i nie jest jednoznacznie ustalona. Inną możliwością jest rozpoznawanie całych dłuższych fragmentów profilu prędkości, w jakim obecnie znajduje się pojazd [122]. Rozpoznawanie wzorców jazdy może dotyczyć także tylko niektórych cech poruszającego się pojazdu, takich jak zachowanie i styl jazdy kierowcy [123]. Niezależnie od tego jaka cecha podlega rozpoznaniu, przeprowadzane jest ono na podstawie historycznych danych dotyczących profilu prędkości, według którego pojazd obecnie się porusza. W większości przypadków określa się pewne okno czasowe, na podstawie, którego rozpoznaje się określony wzorzec poruszania się pojazdu. Pomimo, że do określenia wzorców jazdy stosuje się dane historyczne, to określany wzorzec zawsze

dotyczy aktualnej sytuacji pojazdu. Na podstawie rozpoznanego wzorca jazdy wprowadza się, następnie, właściwe dla danego wzorca strategie zarządzania energią w pojeździe, mające na celu minimalizację konsumpcji energii w pojeździe [8].

W artykule [124] wykorzystano rozpoznawanie wzorców jazdy do optymalnego zarządzania energią w *HEV* o konfiguracji szeregowej. W zaproponowanym rozwiązaniu, w pierwszym kroku, przeprowadzono optymalizację offline z wykorzystaniem algorytmu optymalizacji rojem cząstek (*PSO*), dla dwudziestu znanych profili prędkości. Na podstawie optymalizacji uzyskano optymalne wartości parametrów kontrolnych, które sterowały procesem zarządzania energią w pojeździe. Były one stałe dla każdego z 20 badanych profili prędkości. Następnie, podczas pracy, za pomocą rozpoznawania wzorców jazdy określano w czasie rzeczywistym, do którego wzorcowego profilu prędkości najbardziej zbliżony jest przebieg aktualnego profilu prędkości pojazdu. Jako parametry zarządzające energią w pojeździe, przyjmowano parametry optymalne dla profilu prędkości najbardziej podobnego do aktualnego profilu prędkości. Rozpoznawanie wzorców jazdy następowało dynamicznie i w czasie pojedynczego przejazdu przyjmowało różne profile prędkości, jako najbardziej podobne do aktualnego profilu. Tym samym strategia zarządzania energią w pojeździe podlegała dynamicznym zmianom. Do porównywania parametrów profili prędkości używano odległości euklidesowej w przestrzeni parametrów określających profil prędkości. Do opisanego profilu używano 10 parametrów charakteryzujących liczbę zatrzymań pojazdu, prędkość pojazdu oraz jego przyspieszenie i wytracanie prędkości. Decyzja o rozpoznaniu konkretnego, najbardziej zbliżonego profilu prędkości pojazdu, była podejmowana w pewnym stałym interwale czasowym i obejmowała dłuższy okres, w którym dana strategia obowiązywała. Zastosowanie rozpoznawania wzorców jazdy pozwoliło na zmniejszenie konsumpcji energii w pojeździe o 10% w stosunku do strategii referencyjnej, będącej strategią o stałych parametrach.

W pracy [122] wykorzystano *DPR* do rozpoznawania aktualnie przebiegającego fragmentu profilu jako jednego z kilku charakterystycznych fragmentów profilu prędkości. Opisane w ten sposób fragmenty profilu prędkości zostały nazwane blokami profilu prędkości. Jako wzorcowe, wykorzystano ogólnie znane profile prędkości: *CBDC*, *ECE- EUDC* oraz *MANHATTAN*. Na ich podstawie wyróżniono 3 podgrupy bloków. Klasyfikacja następowała na podstawie prędkości maksymalnej i średniej dla określonego okna czasowego. Istotne w tym przypadku było wykorzystanie logiki rozmytej do rozpoznawania, z którym wzorcem jazdy mamy do czynienia i w jakim stopniu. Głównym celem artykułu była minimalizacja kosztów przejazdu. Nie uzyskano niestety dużych oszczędności, które maksymalnie wyniosły 1,5%. Podobne podejście zastosowano w pracy [121]. Autorzy wykorzystali *DPR* w połączeniu z logiką rozmytą, w celu zarządzania energią w *HEV* w czasie rzeczywistym. Zdecydowano się na zastosowanie 4 wzorców jazdy, do których zaliczono: jazdę z częstymi zatrzymaniami, jazdę w ruchu miejskim, jazdę w obszarach poza miastem i na autostradzie. Do podanych wzorców jazdy zostały zaklasyfikowane fragmenty znanych profili prędkości, takich jak: *MANHATTAN*, *UDDS*, *US06H* oraz *NYCC*. Następnie dla fragmentów profilu prędkości odnoszących

się do poszczególnych wzorców jazdy obliczono z wykorzystaniem programowania dynamicznego optymalne parametry sterujące. W kolejnym kroku ustalono jeden zestaw parametrów, wspólny dla całego wzorca jazdy. Klasyfikacja do poszczególnych wzorców jazdy następowała na podstawie parametrów obliczanych w 100 sekundowym oknie czasowym. Najważniejszy z nich dotyczył średniej prędkości pojazdu w oknie czasowym. Po ustaleniu aktualnie obowiązującego profilu prędkości, jako aktualne parametry sterujące przyjmowano parametry określone wcześniej dla danego wzorca jazdy. W stosunku do tradycyjnego sterowania udało się zmniejszyć zużycie energii o niecałe 4%, podczas gdy przy użyciu programowania dynamicznego uzyskano poprawę rzędu 8,5%.

Znacznie bardziej rozbudowane podejście do tematu *DPR* zostało przedstawione w [125]. Pojęcie wzorca jazdy zostało tam rozbite na bardziej szczegółowe wzorce dotyczące: stylu prowadzenia pojazdu przez kierowcę, trendu jazdy, typu drogi oraz ogólnej charakterystyki aktualnej sytuacji drogowej. Sam algorytm rozpoznawania wzorców jazdy stanowił pierwszy element architektury, którego zadaniem było dostarczanie informacji do kolejnych elementów architektury, których zadaniem był podział momentu obrotowego silnika, gdyż algorytm dotyczył pojazdu hybrydowego o architekturze równoległej. Sam zastosowany algorytm rozpoznawania wzorców jazdy również składał się z kilku modułów. Zadaniem pierwszego elementu było obliczenie parametrów wymaganych dla innych modułów. Jego wyjście stanowiło 16 parametrów kluczowych dla kolejnych modułów. Były one obliczane bezpośrednio na podstawie historycznego zapisu aktualnego profilu prędkości pojazdu. Kolejny element charakteryzował już bezpośrednio warunki w jakich poruszał się pojazd i składał się z 4 mniejszych modułów. Pierwszy z nich był odpowiedzialny za zidentyfikowanie typu drogi, na której pojazd aktualnie się porusza oraz natężenia ruchu panującego na trasie. Klasyfikacja dokonywana była do jednego z 9 profili prędkości, opracowanych na potrzeby klasyfikacji ruchu pojazdów [126]. Do samej klasyfikacji wykorzystano sieci neuronowe o strukturze typu *LVQ*. Klasyfikacja ma za zadanie zidentyfikowanie odpowiedniego profilu prędkości w zakresie 100-140 s. Klasyfikator opisany w artykule został bardzo dokładnie przedstawiony. Zadaniem kolejnego elementu było wykrywanie sytuacji pojazdu w krótkim okresie czasowym. Dotyczyły one takich sytuacji jak przyspieszanie, hamowanie, jazda z niską prędkością, wysoką prędkością, itd. Klasyfikacji dokonywano na podstawie średniej prędkości pojazdu oraz średniego przyspieszenia. W skład tego elementu wchodził także blok rozmywania, który zamieniał wartości średniej prędkości i przyspieszenia na stopień przynależności odpowiednich zbiorów lingwistycznych. Stanowiło to wejście do opartego na logice rozmytej bloku odpowiedzialnego za dystrybucję momentu napędowego. Kolejny algorytm z 4 odpowiedzialnych za opis sytuacji drogowej w jakiej znajduje się pojazd, odpowiadał za interpretację intencji kierowcy pojazdu. Wyróżniono następujące możliwe stany pojazdu: rozpoczynanie jazdy, przyspieszanie, jazda z stałą prędkością, hamowanie, oraz zatrzymanie. Klasyfikacji dokonywano na podstawie aktualnego momentu napędowego pojazdu, przy czym dokonywano rozróżnienia na moment niezbędny do podtrzymania aktualnej prędkości pojazdu oraz moment konieczny do hamowania i przyspieszania. Mechanizm klasyfikacji sprowadzał się do krótkiego zestawu reguł określających znak wspomnianych

powyżej momentów obrotowych. Ostatni moduł odpowiadał za rozpoznanie stylu prowadzenia pojazdu przez kierowcę. Wyróżniono spokojny styl prowadzenia, normalny styl prowadzenia oraz agresywny styl prowadzenia pojazdu. W spokojnym stylu prowadzenia, kierowca unikał gwałtownego hamowania i przyspieszania oraz w miarę możliwości zatrzymań pojazdu. W przypadku agresywnego stylu prowadzenia pojazdu, kierowca często dokonywał gwałtownych hamowań oraz przyspieszania. W celu identyfikacji konkretnego stylu jazdy wykorzystano parametry dotyczące średniego przyspieszenia pojazdu oraz jego odchylenia standardowego. Sama klasyfikacja była wykonywana z wykorzystaniem logiki rozmytej.

W artykule [127,] do klasyfikacji wzorców jazdy, wykorzystano sztuczne sieci neuronowe. Sztuczne sieci neuronowe dobrze sprawdzają się w wszelkiego typu klasyfikacji, nie tylko związanej z *DPR*. We wspomnianym przypadku oprócz sieci neuronowych wykorzystywano dane z czujników *GPS* oraz akcelerometrów zainstalowanych w pojeździe. Na podstawie akcelerometru określano czy pojazd przyspiesza, hamuje, porusza się z relatywnie stałą prędkością bądź wykonuje gwałtowny manewr. W ostatnim przypadku następowały gwałtowne zmiany przyspieszeń, połączone z kierunkiem ich występowania. Na podstawie *GPS* określano krzywiznę toru po jakim poruszał się pojazd. Klasyfikacja następowała tylko na podstawie wymienionych powyżej czynników. Innym możliwym wykorzystaniem metod sztucznej inteligencji do *DPR* jest wykorzystanie maszyny wektorów nośnych - *SVM* [128-129]

W pracy [128] badano możliwości wykorzystania *SVM* do rozpoznawania wzorców jazdy. Początkowo klasyfikator miał za zadanie zaklasyfikować profil prędkości do jednego z dwóch wzorców, przy czym pary tych wzorców badane były różną konfiguracją czterech wzorców, na które składały się: jazda po autostradzie, jazda drogami wiejskimi, jazda miejska przy dużym natężeniu ruchu oraz jazda miejska przy małym natężeniu ruchu drogowego. W kolejnym kroku zadaniem algorytmu była już bezpośrednia klasyfikacja profilu prędkości pojazdu do jednego z 4 wzorców jazdy. Zaproponowany algorytm potrafił dokonać poprawnej klasyfikacji w zdecydowanej większości przypadków. W pracy nie skupiano się na aspekcie dalszego wykorzystania informacji o rozpoznanym wzorcu do zarządzania energią w pojeździe.

Kolejna koncepcja została opisana w [129]. W pracy wykorzystano *SVM* do identyfikacji charakterystycznego parametru profilu prędkości, nazwanego przez autorów wrażliwością profilu (*ang. driving cycles sensitivity*). Na podstawie zidentyfikowanego parametru dokonywano następnie korekty w zarządzaniu energią w pojeździe. Maksymalna oszczędność płynąca z zastosowania metody wynosiła 2%.

2.6 Programowanie dynamiczne

Programowanie dynamiczne (*ang. DP, Dynamic Programming*) zostało zaproponowane przez Richarda Bellmana w latach 50-tych do rozwiązywania nieliniowych, dynamicznych systemów [130]. Programowanie dynamiczne polega na podziale złożonego problemu optymalizacji na sekwencje zależnych od siebie kroków. Sekwencja taka może dotyczyć czynności faktycznie rozłożonych w czasie, bądź też problemów, które nie zależą od czasu, jednak mogą zostać przedstawione jako sekwencja kolejnych kroków. W praktyce metoda jest najczęściej wykorzystywana do optymalizacji procesów, w których aktualnie podejmowane decyzje, mają wpływ na przyszły stan obiektu, który z kolei ma wpływ na przyszłe decyzje. Z dokładnie taką sytuacją mamy do czynienia w przypadku zarządzania energią w pojeździe, ponieważ bieżące decyzje mają wpływ na przyszły SOC akumulatorów oraz superkondensatorów. Zasada programowania dynamicznego opiera się na twierdzeniu, że optymalną decyzją jest ta, dla której suma kosztów związanych z tą decyzją oraz przyszłych kosztów wynikających z tej decyzji, przy stosowaniu optymalnych decyzji w kolejnych krokach, osiąga minimum [130]. Aby było możliwe zastosowanie programowania dynamicznego do optymalnego zarządzania energią w pojeździe, konieczna jest znajomość, z wyprzedzeniem, dokładnego zapotrzebowania na energię w pojeździe. Tego typu *DP* nazywane jest deterministycznym *DP* (*ang. DDP, Deterministic Dynamic Programming*). Z tego powodu *DP* może być bezpośrednio stosowane do zarządzania energią w pojazdach jedynie offline. W przypadku wykorzystania online konieczne jest zastosowanie dodatkowych algorytmów, które pozwolą na predykcję zapotrzebowania na energię pojazdu. Jednym z nich może być *MPC*, które w takim przypadku dostarcza predykcji prędkości pojazdu bądź jego zapotrzebowania na energię [11]. Optymalizacja, w takim przypadku, może odbywać się z użyciem *DDP* w krótkim, kilkusekundowym horyzoncie czasowym, w ramach którego *MPC* dokonuje predykcji. Ze względu na nieliniową charakterystykę napędu *HEV*, problem optymalizacji z użyciem *DP* musi być rozwiązany numerycznie z użyciem aproksymacji. Ponieważ dokładność aproksymacji wpływa bezpośrednio na liczbę koniecznych do wykonania obliczeń i jednocześnie zwiększa dokładność optymalizacji, konieczne jest osiągnięcie kompromisu [7]. Powinien on zapewniać wystarczające wyniki optymalizacji, przy akceptowalnej złożoności obliczeń. Deterministyczne programowanie dynamiczne zyskało dużą popularność w dziedzinie zarządzania energią w pojazdach *HEV*. Pierwsza praca, wykorzystując *DDP* do optymalnego zarządzania energią w *HEV*, pojawiła się już w 1998 roku [131]. Od tego czasu *DDP* zostało wielokrotnie zastosowane do zarządzania energią w różnych pojazdach *HEV* - wliczając *HEV* o architekturze równoległej [132], szeregowo- równoległej [23], oraz *PHEV* [11]. Zastosowanie *DDP* często ma za zadanie utworzenie prostych, optymalnych i możliwych do wdrożenia reguł [132, 7] lub ma na celu osiągnięcie optymalnego wykorzystania energii w pojeździe [133]. Ponieważ optymalizacja przeprowadzona z wykorzystaniem *DDP* daje zawsze rozwiązanie optymalne w granicach założonej dokładności, metoda wykorzystywana jest często jako

wzorcową dla innych metod [7]. Dużą wadą programowania dynamicznego jest konieczność znajomości profilu prędkości pojazdu bądź jego zapotrzebowania na energię. Konieczność ta powoduje także, że wszystkie wyniki dotyczące sygnałów sterujących bądź reguł utworzonych dzięki programowaniu dynamicznemu są prawdziwe jedynie dla profili prędkości, dla których zostały one utworzone. Dodatkowo zastosowanie programowania dynamicznego i najczęściej przyjęta metoda obliczeń, polegająca na określaniu optymalnej strategii od tyłu, często wymuszają przeprowadzenie obliczeń dla wszystkich możliwych stanów, w jakich może znaleźć się obiekt. Przy czym należy tu pamiętać o przyjętej dokładności. Aby możliwe było przewyciężenie trudności związanych z brakiem możliwości przeniesienia wyników na nowy profil prędkości, opracowano stochastyczne programowanie dynamiczne, zwane inaczej łańcuchami Markowa. Zostało ono już opisane w poprzednich częściach niniejszej rozprawy.

3 Hierarchiczna metoda zarządzania energią w pojazdach hybrydowych typu plug-in

Po zapoznaniu się z aktualnie wykorzystywanymi metodami zarządzania energią w pojazdach *HEV*, autor niniejszej rozprawy zdecydował o zaproponowaniu swojej metody, będącej rozwinięciem innych metod. W opinii autora, na szczególną uwagę zasługują te metody i algorytmy, które umożliwiały bezpośrednią aplikację w pojeździe oraz pozwalały na działanie w sytuacji dużej niepewności warunków jazdy oraz profilu prędkości pojazdu. Dodatkowo na korzyść rozwoju metod możliwych do zastosowania online przemawia fakt, że metody te są już w dużej mierze dość dobrze opracowane, z kolei gwałtownie rosnąca moc obliczeniowa komputerów sprawia, że problemy związane z długim czasem obliczeń z każdym kolejnym rokiem maleją. Dodatkowo na szczególną uwagę zasługują metody, których zadaniem jest optymalne zarządzanie energią w *HEV* przy braku dodatkowych informacji o poruszającym się pojeździe, pochodzących na przykład z czujników *GPS*. Algorytmy te muszą najczęściej polegać jedynie na dotychczasowej historii przejazdu. Choć zastosowanie *ITS* rośnie z każdym kolejnym rokiem, to jednak rozwój metod nie korzystających z dodatkowych czujników może stanowić dobrą bazę, która może być następnie uzupełniana o dane pochodzące z innych czujników, co może poprawić jakość zarządzania energią i przyczynić się do zwiększenia sprawności pojazdu *HEV*. Z wyżej wymienionych powodów autor niniejszej rozprawy zdecydował się na zaproponowanie metody, która byłaby możliwa do aplikacji online oraz nie wykorzystywałaby podczas pracy innych informacji poza zapisem prędkości pojazdu z danego przejazdu. Autor proponuje syntezę kilku metod, które aktualnie są już znane i pozostają w sferze zainteresowań innych badaczy.

W kontekście zainteresowań autora rozprawy, na szczególną uwagę zasługują metody zarządzania energią w *HEV* oparte na *MPC*. Wiele z nich umożliwia dobrą predykcję prędkości pojazdu, bazując jedynie na aktualnym stanie pojazdu bądź na historycznej prędkości pojazdu zarejestrowanej podczas aktualnego przejazdu. Metody te często wydają się jednak zbyt uniwersalne i nie uwzględniają one aktualnych warunków panujących na trasie i w podobny sposób dokonują predykcji prędkości pojazdu zarówno podczas jazdy na autostradzie jak i w zatłoczonym mieście. Przykładem może być *MPC* wykorzystujący strategię zmienną eksponentialnie, dla której parametry określające sposób predykcji są niezależne od aktualnie panujących warunków na trasie oraz typu samej drogi. Jednocześnie *MPC* umożliwia wykorzystanie dobrych i dokładnych metod optymalizacji, takich jak *DDP* [11]. Z wyżej wymienionych powodów, autor niniejszej rozprawy zdecydował, że metody *MPC* idealnie nadają się jako rdzeń proponowanej przez niego metody.

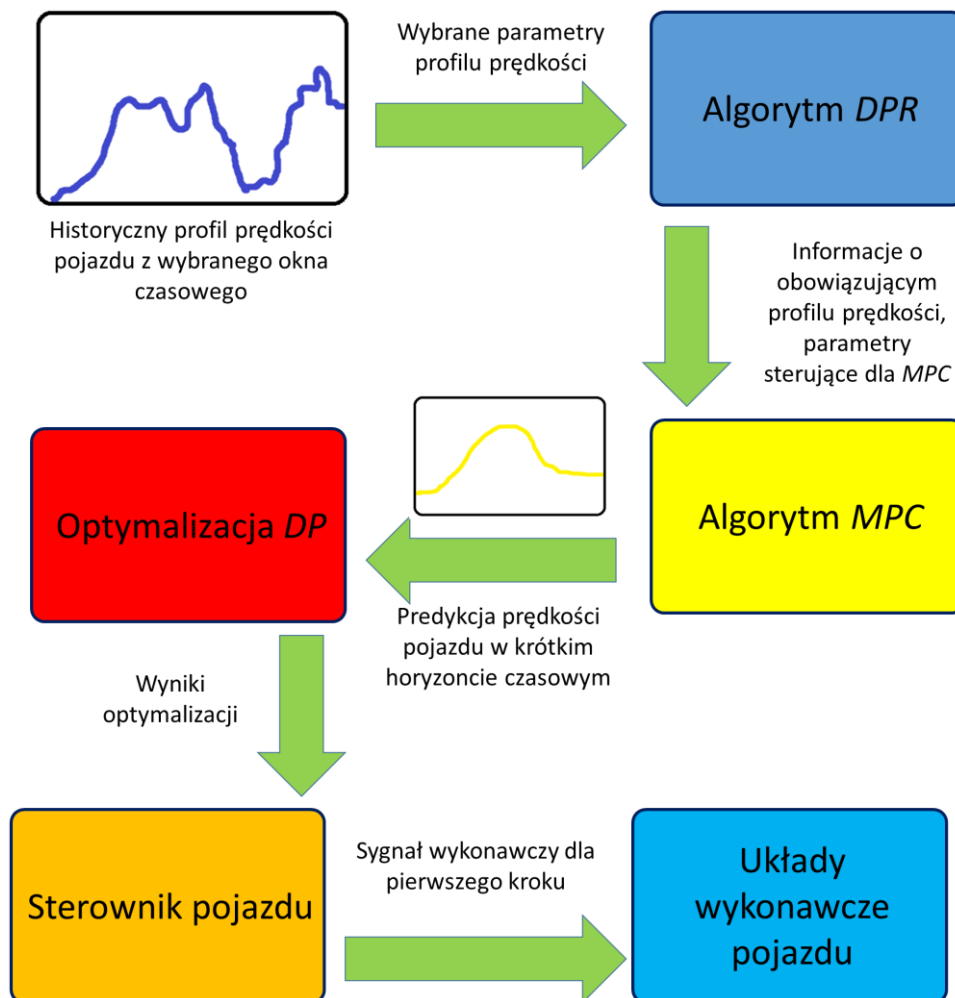
Ponieważ pojazdy *HEV* o różnej konfiguracji wymagają różnych metod, autor zdecydował o ograniczeniu zakresu niniejszej rozprawy do pojazdu *HEV* o wybranej architekturze. Współcześnie stale wzrasta liczba pojazdów *EV*. Wydaje się to być główną gałęzią rozwoju współczesnej motoryzacji. Mają one niewątpliwe zalety w postaci niższych kosztów eksploatacji, braku emisji zanieczyszczeń

w miejscu użytkowania oraz możliwości ładowania pojazdu z rozproszonej infrastruktury, przykładowo w miejscu zamieszkania użytkownika. Ich wadą jest jednak ograniczony zasięg. Naprzeciw tym wyzwaniom wychodzą pojazdy *PHEV* o konfiguracji szeregowej. Mają one wydłużony zasięg pracy na baterii, w stosunku do klasycznych *HEV* o architekturze szeregowej oraz możliwość ładowania baterii z gniazdka lub stacji ładowania. Zasięg pracy pojazdu jedynie z wykorzystaniem akumulatora, najczęściej pozwala na codzienne poruszanie się w pobliżu miejsca zamieszkania. Jeśli występuje potrzeba przejechania większej odległości mają one możliwość uzupełnienia energii poprzez doładowanie akumulatorów z energii produkowanej przez generator, połączony z silnikiem spalinowym. W ten sposób możliwe jest uzyskanie pojazdu o niskich kosztach eksploatacji, możliwego do ładowania poprzez rozproszoną infrastrukturę oraz najczęściej bezemisyjnego w miejscu użytkowania, przy dużym zasięgu samego pojazdu. Ze względu na te cechy oraz trendy w obecnej motoryzacji, zdecydowano się na zawężenie zakresu działania metody prezentowanej w niniejszej rozprawie do hybrydy *PHEV* o konfiguracji szeregowej.

Aby przezwyciężyć mankament *MPC*, polegający na braku zmienności parametrów mających wpływ na predykcję *MPC*, zdecydowano się na wprowadzenie hierarchicznej struktury do nowej metody. Warstwę nadrzędną stanowić będzie algorytm *DPR*, którego zadaniem będzie określenie z jakimi warunkami oraz typem drogi mamy aktualnie do czynienia. Kolejnym etapem będzie algorytm *MPC*, którego parametry związane z predykcją będą zależeć od typu drogi i warunków jazdy. Parametry *MPC* na wcześniejszym etapie zostaną poddane optymalizacji, tak by były one optymalne dla danych warunków jazdy i nie musiały być optymalizowane za każdym razem. Przyczyni się to do znacznego zmniejszenia koniecznych nakładów obliczeniowych. Ponieważ parametry sterujące predykcją będą w danym momencie pochodziły z algorytmu *DPR*, można powiedzieć, że jest on nadrzędny w stosunku do *MPC*. W kolejnym etapie w oparciu o wynik predykcji prędkości strategia zarządzania energią będzie poddana optymalizacji *DDP*. Ostateczne sygnały sterujące, które będą decydowały o realizacji strategii zarządzania energią w pojeździe, będą pochodziły z sterownika realizującego pierwszy krok strategii otrzymanej z *DDP*. Algorytm *DP* będzie pracował w ramach ograniczonego horyzontu czasowego oraz z założoną dokładnością, co pozwoli na możliwość uzyskania wyników w czasie rzeczywistym. Następnie po przejściu do kolejnego kroku, działanie całej metody zostanie powtórzone. Schemat zaproponowanej hierarchicznej metody zarządzania energią w pojeździe *HEV* został przedstawiony na Rys. 10.

Zaproponowana metoda wykorzystuje wiele różnych metod i algorytmów. Jednocześnie została ona utworzona z myślą o możliwości zastosowania online. Z tego powodu zaproponowane algorytmy i metody nie mogą cechować się zbyt dużymi nakładami obliczeniowymi i powinny być relatywnie proste w implementacji. Były to główne kryteria wyboru konkretnych rodzajów poszczególnych metod i algorytmów. W przypadku algorytmu *DPR* zdecydowano się na zastosowanie porównania wektorów zawierających parametry profilu prędkości pojazdu w wybranym oknie czasowym, zmieniającym się z każdym krokiem. Na obecnym etapie rozwoju metody zdecydowano się nie brać pod uwagę informacji

nie pochodzących z profilu prędkości pojazdu, takich jak położenie *GPS* itd. W przyszłości istnieje możliwość rozbudowy algorytmu o inne parametry. Porównanie wektorów zawierających wybrane parametry profilu prędkości daje dobre rezultaty przy jednocześnie niskiej wymaganej mocy obliczeniowej i jest łatwe w implementacji. Wybrano 8 wzorców jazdy, z którymi będzie porównywany aktualny profil prędkości pojazdu. Szczegółowe dane dotyczące samych wzorców jazdy jak i parametry algorytmu *DPR*, zostały przedstawione w dalszej części niniejszej rozprawy.



Rys. 10. Schemat proponowanej metody zarządzania energią w pojeździe.

Jako algorytm *MPC* zdecydowano się zastosować sterowanie predykcyjne zmienne eksponentyjalnie. Decyzja ta, była podyktowana przede wszystkim łatwą implementacją takiej strategii oraz prostotą sterowania, która ogranicza się do podania pojedynczego parametru, określającego sposób predykcji dla konkretnego wzorca jazdy, zgodnie z którym obecnie porusza się pojazd. Zmienny parametr sterujący predykcją umożliwia zwiększenie dokładności predykcji i tym samym poprawę efektywności wykorzystania energii w pojeździe. Podobnie jak w przypadku algorytmu *DPR*, dokładne parametry metody i sposób działania *MPC* zostały opisane w kolejnych podrozdziałach niniejszej rozprawy. Kolejnym krokiem jest wykorzystanie *DDP*. Algorytm *DDP* wymaga sporych nakładów

obliczeniowych, umożliwia on jednak uzyskanie dokładnego, optymalnego rozwiązania w ramach założonej dokładności. Programowanie dynamiczne często bywa jednak wykorzystywane jako metoda określająca optymalną strategię zarządzania w *HEV*, w przypadku zastosowania *MPC*. Wymagana moc obliczeniowa może być ograniczona przez zmniejszenie rozdzielczości pola możliwych rozwiązań, zmniejszając dokładność wyniku. Dodatkowo złożoność obliczeń ograniczona jest poprzez krótki, kilkusekundowy horyzont czasowy. Z wyżej wymienionych powodów zdecydowano się na zastosowanie *DDP*, pomimo dużej złożoności obliczeń ograniczających możliwość wykorzystania online. Szczegółowe parametry metody zostały opisane w kolejnych rozdziałach niniejszej rozprawy, podobnie jak ma to miejsce z samym modelem pojazdu.

4 Model symulacyjny

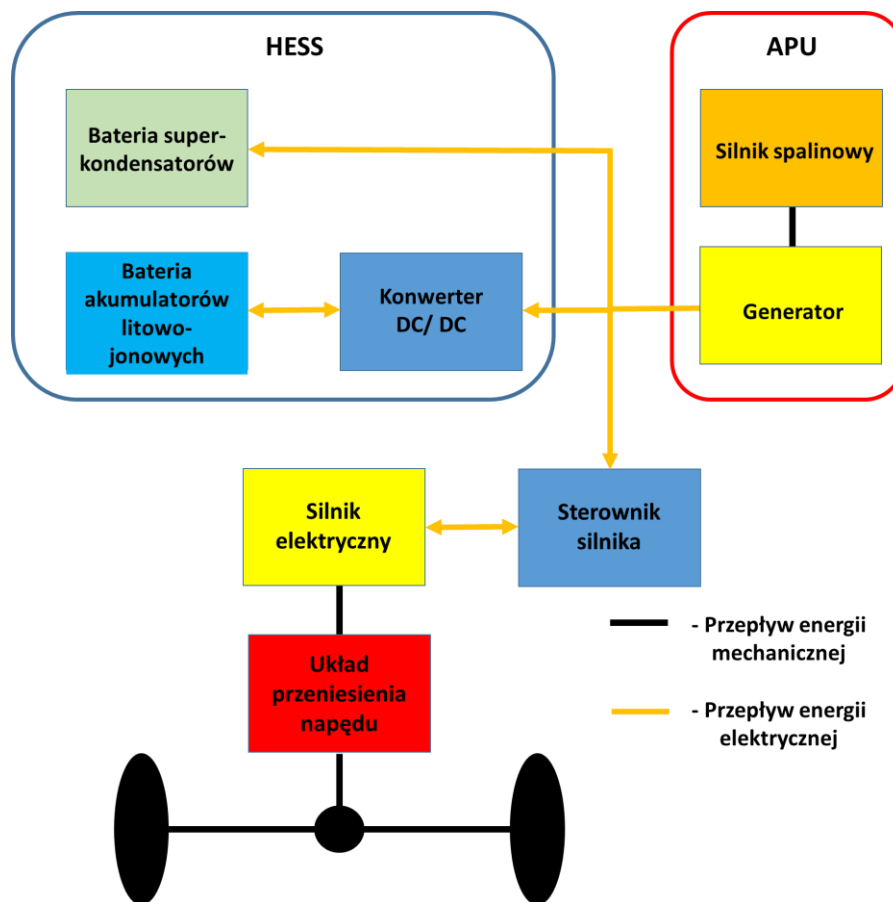
Badania prowadzone w ramach niniejszej rozprawy doktorskiej miały charakter numeryczny. Miały one na celu symulację przepływu energii w pojeździe. W badaniach nie skupiano się na dokładnym modelowaniu całego pojazdu i otoczenia, a jedynie na elementach istotnych z punktu widzenia zarządzania energią w pojeździe. W ramach badań opracowano model pojazdu oraz poszczególne funkcje i algorytmy składające się na proponowaną metodę zarządzania energią w pojeździe. Ponieważ zarówno sam pojazd może być modelowany w różny sposób, jak i poszczególne rodzaje algorytmów różnią się istotnie między sobą, niniejszy rozdział poświęcono szczegółowemu omówieniu budowy zarówno samego modelu pojazdu, jak i poszczególnych części składowych metody, proponowanej w niniejszej rozprawie.

4.1 Model symulacyjny pojazdu

Model pojazdu obejmuje jedynie elementy mające bezpośredni wpływ na zarządzanie energią w pojeździe. Aby możliwe było przeprowadzenie konkretnych obliczeń, zdecydowano się wykorzystać jako przykład ciężarowy pojazd *PHEV*. Wybór konkretnego pojazdu podyktowany był zarówno mniejszą dynamiką jazdy samochodu ciężarowego, a co za tym idzie mniejszą zmiennością prędkości i jej wyższą przewidywalnością, ale także wysoką dostępnością danych na temat pojazdu [11, 122]. Wybór ciężarówki jest także bardziej zasadny ze względów ekonomicznych. Ze względu na przeznaczenie, samochody ciężarowe muszą wykazywać się wysoką sprawnością i niskimi kosztami przejazdu. Pojazd jest także ciekawy pod względem badań naukowych, gdyż oprócz akumulatorów oraz generatora sprzężonego z silnikiem spalinowym, dysponuje on baterią superkondensatorów wykorzystywanych podczas hamowania z odzyskiem energii.

Budowę pojazdu pod względem przepływu energii można podzielić na następujące elementy: układ przeniesienia napędu, silnik elektryczny, sterownik silnika oraz hybrydowy magazyn energii (*ang. HESS, Hybrid Energy Storage System*) i jednostkę pomocniczą (*ang. APU, Assistant Power Unit*). W skład *HESS* wchodzi bateria akumulatorów litowo-jonowych, bateria superkondensatorów oraz konwerter *DC-DC*. W skład jednostki pomocniczej *APU* wchodzi silnik spalinowy oraz generator wraz z prostownikiem napięcia. Podstawowym źródłem energii w pojeździe jest *HESS*, zaś zadaniem *APU* jest doładowywanie akumulatorów pojazdu, w razie wystąpienia takiej potrzeby. Przepływ energii pomiędzy poszczególnymi elementami pojazdu został przedstawiony na Rys.11. Dodatkowo modelowano opory pojazdu, które następnie były bazą do obliczania energii wykorzystywanej przez pojazd. W pracy nie uwzględniono wpływu dodatkowych elementów zużywających energię w pojeździe, takich jak światła, klimatyzacja itd. Wpływ tego typu elementów jest niewielki przy mocach układu napędowego ciężarówki, nie stanowi on także głównego zagadnienia badawczego

niniejszej rozprawy. Każdy z elementów został osobno zamodelowany, zaś cały model utworzony został z wykorzystaniem oprogramowania Matlab.



Rys. 11. Schemat modelu pojazdu

Dane dotyczące parametrów pojazdu zostały zaczerpnięte z [11, 122] i przedstawione w tabeli 1

Wielkość	Symbol	Wartość
Masa wraz z ładunkiem	m	16500 [kg]
Współczynnik oporu toczenia	f	0,011 [m]
Powierzchnia przednia ciężarówki	A	6,6 [m ²]
Współczynnik oporu aerodynamicznego	C_x	0,55

Tab. 1 Podstawowe dane modelowanego pojazdu

W pojeździe oryginalnie zastosowana była strategia pracy w dwóch trybach: ładowania i rozładowywania akumulatorów. Strategia ta jest strategią wzorcową, wobec której porównywane będą wyniki. W trybie rozładowywania pojazd pracuje jak EV i energia potrzebna do napędu pochodzi w zdecydowanej większości z akumulatorów pojazdu. Kiedy poziom naładowania akumulatorów SoC spadnie poniżej pewnej wartości (ustalonej jako 0,35), pojazd przechodzi w tryb rozładowania i pracuje

jako *HEV*. *SOC* akumulatorów utrzymywany jest w tym trybie, w przybliżeniu na poziomie 0,3. Dokładne zachowanie się pojazdu może zostać opisane przez poniższy zestaw reguł [11]:

- 1) Tryb rozładowywania: obowiązuje w przypadku gdy *SoC* akumulatorów wynosi powyżej 0,35. W takim przypadku *APU* pozostaje wyłączona i moc *APU* wynosi 0 ($P_{APU} = 0$), zaś cała moc układu napędowego pochodzi z hybrydowego magazynu energii *HESS* ($P_{HESS} = P_n$). Zarządzanie energią w ramach *HESS* odbywa się według następujących reguł:
 - a. JEŻELI $P_{HESS} < 0$, i $USoC_H < 0$ TO $P_B = P_{HESS}$ i $P_{uc} = 0$,
 - b. JEŻELI $P_{HESS} < 0$, i $USoC_H \geq 0$ TO $P_B = 0$ i $P_{uc} = P_{HESS}$,
 - c. JEŻELI $0 \leq P_{HESS} < P_L$, $USoC > USoC_L$ i $BSoC > BSoC_L$ TO $P_B = P_{HESS}$ i $P_{uc} = 0$,
 - d. JEŻELI $P_L \leq P_{HESS}$, $USoC > USoC_L$ i $BSoC > BSoC_L$ TO $P_B = P_L$ i $P_{uc} = P_{HESS} - P_L$,
 - e. JEŻELI $0 \leq P_{HESS}$, $USoC \leq USoC_L$ i $BSoC > BSoC_L$ TO $P_B = P_{HESS}$ i $P_{uc} = 0$,
 - f. JEŻELI $0 \leq P_{HESS}$, $USoC > USoC_L$ i $BSoC \leq BSoC_L$ TO $P_B = 0$ i $P_{uc} = P_{HESS}$,
 - g. JEŻELI $0 \leq P_{HESS}$, $USoC \leq USoC_L$ i $BSoC \leq BSoC_L$ TO $P_B = 0$ i $P_{uc} = 0$,
- 2) Tryb ładowania: obowiązuje w przypadku gdy *SoC* akumulatorów wynosi równo lub poniżej 0,35. W tym przypadku *APU* zostaje uruchomione, dzięki czemu możliwe jest ładowanie akumulatorów. *APU* może zostać także uruchomione w przypadku gdy moc możliwa do dostarczenia przez *HESS* jest niższa od mocy wymaganej do napędzenia pojazdu. W takim wypadku deficyt mocy zaspokojony zostaje przez *APU* zgodnie z równaniem:

$$P_{APU} = P_n - P_{HESSmax} \quad (7)$$

W przypadku gdy *BSoC* spadnie poniżej 0,35, podział mocy realizowany jest według następujących reguł:

- a. JEŻELI $P_n < 0$, TO $P_{HESS} = P_n$ i $P_{APU} = 0$,
- b. JEŻELI $P_n > P_r$ TO $P_{HESS} = P_n - P_{APU}$ i $P_{APU} = P_r$,
- c. JEŻELI $0 \leq P_n \leq P_r$ i $BSoC \leq 0,25$ TO $P_{APU} = P_r$ DOPÓKI $BSoC > 0,35$ i $P_{HESS} = P_n - P_{APU}$,
- d. JEŻELI $0 \leq P_n \leq P_r$ i $BSoC \geq 0,25$ TO $P_{APU} = 0$ i $P_{HESS} = P_n$.

Podział energii w ramach *HESS* jest w tym wypadku identyczny jak dla trybu rozładowywania. W powyższych regułach P_{HESS} , oznacza moc hybrydowego magazynu energii, P_{APU} oznacza moc jednostki pomocniczej, P_B symbolizuje moc pakietu akumulatorów, P_n symbolizuje moc wymaganą przez układ napędowy pojazdu, P_{uc} oznacza moc pochodzącą z baterii superkondensatorów, P_r , symbolizuje maksymalną moc *APU* (ustawioną na 75 kW), P_L jest progiem mocy dla *HESS* (38,16 kW), $USoC_H$ i $USoC_L$ oznaczają kolejno dolny i górny poziom naładowania superkondensatorów wynoszący


kolejno 0,51 i 0,99, $BSoC_L$ oznacza dolny minimalny poziom naładowania akumulatorów wynoszący 0,2, $USoC$ jest poziomem naładowania superkondensatorów, zaś $BSoC$ reprezentuje poziom naładowania akumulatorów.

Dla proponowanej w niniejszej rozprawie metody zarządzania energią w pojeździe *PHEV*, *APU* jest uruchamiane podobnie jak w oryginalnej strategii, tzn. w przypadku spadku poziomu naładowania akumulatorów $BSoC$ poniżej poziomu 0,35. *APU* zostaje także uruchomiane w przypadku przekroczenia mocy wymaganej przez układ napędowy pojazdu ponad moc możliwą do dostarczenia przez *HES*. O ilości energii pobieranej z akumulatora pojazdu decyduje proponowana metoda, opierając się w największym stopniu na algorytmie programowania dynamicznego.

Bateria akumulatorów składa się z 138 $LiMn_2O_4$ litowo-jonowych celi połączonych szeregowo. Nominalna pojemność każdej celi wynosi 77 Ah, zaś napięcie nominalne 3,7 V. Górny zakres napięcia dla pojedynczej celi wynosi 4,2 V, zaś dolne napięcie odcinające wynosi 3,0 V. Daje to maksymalne napięcie akumulatorów wynoszące 579,6 V, zaś napięcie minimalne, przy którym akumulator nie może już pracować, wynosi 414 V [11]. Pakiet akumulatorów został zamodelowany zgodnie z modelem Thevenina. Pozwala to na ujęcie dynamiki akumulatorów. Model może zostać opisany przez poniższy zestaw równań [134]:

$$\begin{cases} \dot{U}_D = -\frac{1}{C_D R_D} U_D + \frac{1}{C_D} i_L \\ U_t = U_{OC} - U_D - i_L R_i \end{cases} \quad (8)$$

Gdzie: U_D oznacza napięcie dyfuzyjne, U_t jest napięciem na zaciskach baterii, zaś U_{OC} oznacza napięcie przy nieobciążonym akumulatorze.



Rys. 12 Parametry pakietu akumulatorów [11]

Oznaczenia R_D i C_D symbolizują kolejno pojemność dyfuzyjną i rezystancję dyfuzyjną dla sieci RC, której zadaniem jest odzwierciedlanie dynamiki napięcia akumulatora oraz efektu transportu masy. Rezystancję poszczególnych elementów akumulatora oznacza R_i , z kolei i_L jest natężeniem prądu rozładowywania (ładowania) akumulatora. Wartości dla poszczególnych parametrów akumulatora zostały przedstawione w formie wykresu na Rys. 12.

Bateria superkondensatorów została zamodelowana jako kombinacja idealnego kondensatora oraz rezystora, połączonych szeregowo [134]. Działanie baterii superkondensatorów może być opisane równaniem [11]:

$$U_{ct} = U_{CO} - R_c i_c \quad (9)$$

Gdzie: R_c oznacza rezystancje elementów baterii superkondensatorów, U_{CO} opisuje napięcie na okładkach superkondensatora, U_{ct} symbolizuje napięcie na zaciskach baterii superkondensatorów, zaś i_c oznacza natężenie prądu rozładowania (ładowania) baterii superkondensatorów. W skład baterii superkondensatorów wchodzi 12 modułów superkondensatorów połączonych szeregowo. Pojemność dla każdego z modułów wynosi 165 F, maksymalne napięcie 48 V, zaś rezystancja wynosi 0,0063 Ω . Łączna pojemność całej baterii superkondensatorów wynosi 13,75 F, jej rezystancja 0,0756 Ω a maksymalne napięcie wynosi 576 V [11].

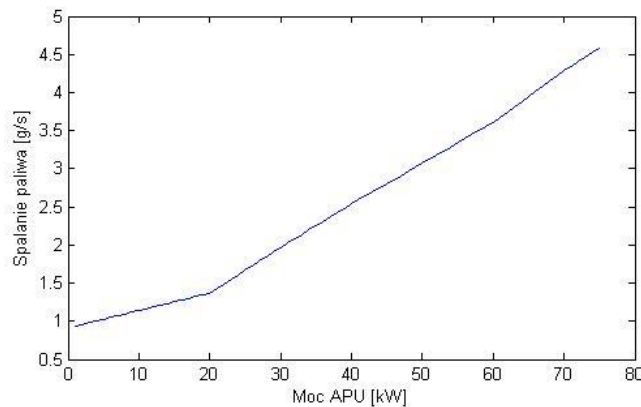
Konwerter DC/DC został zamodelowany jako element o określonej sprawności, zwiększający bądź zmniejszający moc wyjściową lub wejściową do akumulatorów. Mapa sprawności przetwornika została przedstawiona w tab. 2 [11]

Natężenie prądu [A]	Moc podlegająca konwersji [kW]				
	10	20	30	40	≥ 50
10	92%	95%	97%	95%	94%
50	91%	93%	96%	93%	92%
100	88%	91%	95%	92%	91%
≥ 150	82%	89%	92%	91%	90%

Tab. 2 Mapa sprawności przetwornika DC/DC [11]

Jednostka pomocnicza APU składa się z silnika spalinowego o pojemności 1,9 l oraz generatora z magnesami trwałymi o mocy 80 kW. Moc nominalna APU wynosi 75 kW. W przypadku pojazdu PHEV o konfiguracji szeregowej, silnik spalinowy nie jest, w żaden sposób, mechanicznie połączony z kołami pojazdu. Umożliwia to pracę APU w optymalnej krzywej pracy, niezależnie od warunków panujących na drodze oraz aktualnego zapotrzebowania pojazdu na energię. Krzywa pracy dla APU

powstała ze złożenia map sprawności silnika spalinowego i generatora i została przedstawiona na rys. 13 w formie zależności spalania paliwa od mocy wytwarzanej przez *APU* [11].



Rys. 13 Zależność ilości zużywanego paliwa od mocy wytwarzanej przez *APU* [11]

Silnik elektryczny, sterownik silnika oraz układ przełożenia napędu zostały, w niniejszej rozprawie, zamodelowane jako elementy o stałej sprawności. Jest to podyktowane głównie brakiem wiarygodnej mapy sprawności poszczególnych elementów. W przypadku posiadania takiej mapy, bądź możliwości pomiarów danych potrzebnych do jej opracowania, mapa taka może zostać łatwo zaimplementowana. W niniejszej rozprawie za sprawność silnika przyjęto 90%, za sprawność sterownika silnika – 90% a za sprawność układu przeniesienia napędu przyjęto 95%.

Opory pojazdu zostały zamodelowane zgodnie z równaniami opisującymi poszczególne składowe oporów ruchu. W modelu rozpatrywano jedynie dynamikę wzdłużną pojazdu i pominięto inne aspekty dynamiki pojazdu, takie jak straty wynikające z nierówności drogi i odpowiedzi zawieszenia pojazdu[135], czy dodatkowe opory powstałe przez działania wiatru lub innych warunków pogodowych. W takim wypadku zapotrzebowanie na moc pojazdu może zostać opisane za pomocą następującego równania [11]:

$$P_n = (Mgf \cos \alpha + Mg \sin \alpha + \frac{C_x A v^2}{21,15} + \frac{\delta M}{3,6} \frac{dv}{dt}) \frac{v}{3,6 \eta_T \eta_E \eta_C} \quad (10)$$

Gdzie: P_n symbolizuje energię całkowitą oporów pojazdu, wymaganą do pobrania przez układ napędowy pojazdu, v oznacza prędkość pojazdu (km/h), M symbolizuje masę pojazdu, g jest ziemskim przyspieszeniem grawitacyjnym ($9,81 \text{ m/s}^2$), α jest kątem nachylenia drogi do poziomu, C_x oznacza współczynnik oporu aerodynamicznego pojazdu, A symbolizuje powierzchnię czołową pojazdu, δ jest współczynnikiem mas wirujących (1.03), zaś η_T , η_E i η_C , symbolizują kolejno sprawność układu przeniesienia napędu, sprawność silnika elektrycznego i sprawność sterownika silnika elektrycznego pojazdu.

4.2 Realizacja algorytmu rozpoznawania wzorców jazdy DPR

Zadaniem algorytmu rozpoznawania wzorców jazdy w zaproponowanej hierarchicznej metodzie zarządzania energią w pojeździe *PHEV* jest dostarczenie danych o warunkach, w jakich aktualnie porusza się pojazd, do kolejnych, podległych algorytmów. Rozpoznawanie wzorców jazdy jest pierwszym algorytmem wykorzystywanym w metodzie i pełni ono nadrzędną funkcję w stosunku do pozostałych metod i algorytmów. Możliwe sposoby realizacji algorytmu zostały szerzej opisane w podrozdziale 2.5 niniejszej rozprawy. Spośród opisanych tam możliwych rozwiązań zdecydowano się zastosować rozwiązanie oparte o zbieranie danych o przejeździe z określonego okna czasowego i identyfikację charakterystycznych parametrów dla danego przejazdu, a następnie na ich podstawie identyfikację wzorca jazdy, zgodnie z którym porusza się pojazd [124]. Metoda ta jest prosta do zastosowania oraz nie wymaga dużej mocy obliczeniowej, nadaje się tym samym do wykorzystania online.

Zdecydowano się na wybór 8 możliwych scenariuszy jazdy, obejmujących 4 rodzaje dróg oraz dla każdego rodzaju drogi 2 różne scenariusze, w zależności od natężenia ruchu drogowego [18]. Jako scenariusze wybrano: przejazd po autostradzie ze stałą prędkością, przejazd po autostradzie w zmiennych warunkach, przejazd po głównych drogach ze stałą prędkością i przy zmiennych warunkach, przejazd drogami poza terenem zabudowanym ze stałą prędkością i przy zmiennych warunkach oraz przejazd przez tereny miejskie w przypadku niskiego natężenia ruchu i w warunkach przeciążenia ruchem samochodowym [18]. Parametry oraz metodykę konstruowania poszczególnych wzorców jazdy opisano w dalszej części niniejszej rozprawy.

Do identyfikacji wzorca jazdy użyto 8 charakterystycznych parametrów: średniej prędkości pojazdu (km/h), maksymalnej prędkości pojazdu (km/h), maksymalnego przyspieszenia pojazdu (m/s^2), średniego przyspieszenia pojazdu (m/s^2), maksymalnego i średniego opóźnienia pojazdu (m/s^2), czasu postoju (s) oraz ilości zatrzymań. W celu określenia ,z którym wzorcem jazdy mamy do czynienia obliczano odległość pomiędzy punktami reprezentującymi przestrzeń możliwych parametrów profili prędkości, wykorzystując metrykę euklidesową zgodnie z poniższym wzorem [124].

$$d = \sqrt{\sum_{i=1}^8 ((x_{iA} - x_{iB})^2)} \quad (11)$$

Gdzie: d oznacza odległość pomiędzy wzorcowym profilem prędkości a aktualnym profilem prędkości pochodzącym z obecnego przejazdu, x_{iA} oznacza kolejne parametry profilu prędkości pochodzącego z obecnego przejazdu, zaś x_{iB} reprezentuje wartości kolejnych parametrów wzorcowego profilu prędkości. Dokładne wartości poszczególnych parametrów dla wzorcowych profili prędkości zostały opisane w kolejnych częściach niniejszej rozprawy. Opis doboru długości okna czasowego, na

podstawie którego obliczano parametry aktualnie realizowanego profilu prędkości w kolejnych częściach rozprawy doktorskiej.

4.3 Realizacja algorytmu sterowania predykcyjnego MPC

Algorytm *MPC* zajmuje środkowe miejsce w hierarchii zaproponowanej metody zarządzania energią w pojeździe *PHEV*. Zadaniem algorytmu jest predykcja prędkości pojazdu w krótkim horyzoncie czasowym, wynoszącym do 10 s [11]. Predykcja ta jest daną wejściową do optymalizacji z użyciem programowania dynamicznego. Daną wejściową do algorytmu *MPC* jest profil prędkości, z którym pojazd aktualnie się porusza. Na podstawie profilu prędkości dobierany jest parametr sterujący algorytmem. Spośród wielu możliwych do wyboru rozwiązań *MPC*, zdecydowano się na strategię zmienną eksponentylnie [11]. Podstawową zaletę wybranego *MPC* stanowią niskie nakłady obliczeniowe. Dodatkową zaletą jest łatwość sterowania parametrami algorytmu w przypadku strategii zmiennej eksponentylnie. Parametrem sterującym jest w tym przypadku t_d , zgodnie z równaniem 5 lub ε , zgodnie z równaniem 6. Wadą przyjętej strategii jest mniejsza dokładność predykcji, niż ma to miejsce w przypadku innych, bardziej zaawansowanych metod. Niemniej jednak, predykcja ta może dać wystarczająco dobre wyniki w połączeniu z programowaniem dynamicznym. Ponieważ w niniejszej rozprawie doktorskiej priorytetem jest możliwość zastosowania zaproponowanej metody online, a tym samym konieczności stosowania metod i algorytmów o niskim zapotrzebowaniu na moc obliczeniową, autor rozprawy zdecydował o wyborze strategii zmiennej eksponentylnie, jako algorytmu *MPC*. Autor zdecydował się na predykcję prędkości pojazdu zgodnie z równaniem 6. Wielkość horyzontu czasowego, jak i dokładne wartości parametrów sterujących dla poszczególnych wzorcowych profili prędkości pojazdu rozpoznanych w ramach *MPC* zostały szczegółowo opisane w dalszych częściach niniejszej rozprawy.

4.4 Realizacja programowania dynamicznego

Algorytm programowania dynamicznego stanowi ostatni element w proponowanej metodzie zarządzania energią w pojeździe *PHEV*. Głównym zadaniem algorytmu jest ustalenie optymalnej wartości natężenia prądu rozładowania (ładowania) baterii akumulatorów. Ponieważ zapotrzebowanie na moc jest ściśle określone w danym punkcie w czasie, pozostała energia czerpana jest z baterii superkondensatorów i *APU*. Przy czym *APU* zostaje załączone w przypadku spadku *SOC* akumulatorów poniżej pewnego ustalonego poziomu oraz w przypadku bardzo dużego zapotrzebowania na moc, gdy moc możliwa do dostarczenia przez baterię superkondensatorów i akumulatorów jest niższa niż zapotrzebowanie na moc w układzie. Wejściem do algorytmu jest predykcja prędkości pojazdu dla

krótkiego okna czasowego, zaś wyjściem optymalna wartość natężenia prądu rozładowania (ładowania) akumulatorów.

Stan systemu pojazdu może być w każdym punkcie, w czasie jednoznacznie określony przez 3 zmienne: napięcie dyfuzyjne U_D (V), stan naładowania akumulatorów $BSoC$ (0-1) oraz stan naładowania superkondensatorów $USoC$ (0-1). Przy czym 0 oznacza stan akumulatorów bądź superkondensatorów w pełni rozładowany, zaś 1 oznacza stan w pełni naładowany. Z kolei zmienną kontrolną jest natężenie prądu rozładowania akumulatorów i_L (A). W takim przypadku przejście pomiędzy kolejno następującymi po sobie stanami pojazdu może być opisane poniższym zestawem równań [11]:

$$\begin{bmatrix} U_D(k+1) \\ BSoC(k+1) \end{bmatrix} = \begin{bmatrix} \exp\left(\frac{-\Delta t}{R_D C_D}\right) & 0 \\ 0 & 1 \end{bmatrix} * \begin{bmatrix} U_D(k) \\ BSoC(k) \end{bmatrix} + \begin{bmatrix} \left(1 - \exp\left(\frac{-\Delta t}{R_D C_D}\right)\right) R_D \\ \frac{-1}{3600 Q_B} \end{bmatrix} i_L(k) \quad (12)$$

$$USoC(k+1) = \frac{USoC(k) * Q_C - i_c(k)}{Q_C} \quad (13)$$

Gdzie: k oznacza stan w aktualnej chwili, $(k+1)$ oznacza stan w przyszłym, następnym po k momencie. Czas jaki upływa pomiędzy momentem k i $(k+1)$ oznaczono jako Δt . W niniejszej rozprawie, jako Δt przyjęto czas 1 s. Parametry określające rezystancję i pojemność dyfuzyjną oznaczono kolejno jako R_D (Ω) i C_D (F). Nominalną pojemność baterii akumulatorów oznaczono jako Q_B (C), zaś nominalną pojemność superkondensatorów oznaczono jako Q_C (C). Prąd rozładowania superkondensatorów oznaczono jako i_c . Celem optymalizacji jest minimalizacja funkcji kosztu, uwzględniająca zużycie energii w pojeździe, spalanie paliwa w pojeździe oraz relację pomiędzy ceną paliwa i energii elektrycznej. Funkcja kosztu może zostać opisana poniższym zestawem równań [11]:

$$\begin{cases} J = \sum_{k=0}^{N-1} C(X(k), U(k)) = \sum_{k=0}^{N-1} C_B(X(k), U(k)) + C_C(X(k), U(k)) + C_{APU}(X(k), U(k)) \\ C_B(X(k), U(k)) = (i_L(k)U_t(k) + i_L(k)^2 R_i(k) + U_D(k)^2 / R_D) A_E \\ C_C(X(k), U(k)) = (i_c(k)U_{Ct}(k) + i_c(k)^2 R_C(k)) A_E \\ C_{APU}(X(k), U(k)) = \dot{m}(k) A_f \end{cases} \quad (14)$$

Gdzie: J oznacza koszty poniesione w czasie od 0 do $N-1$, $C(X(k), U(k))$ oznacza sumę kosztów w chwili (k) , na którą składają się koszty energii traconej na elementach akumulatora $C_B(X(k), U(k))$, baterii superkondensatorów $C_C(X(k), U(k))$ oraz koszty spalania paliwa przez APU $C_{APU}(X(k), U(k))$. Większość oznaczeń jest zgodna z równaniami 12 i 13, przedstawionymi w tym rozdziale. Nowe oznaczenia dotyczą: napięcia na zaciskach akumulatora U_t (V), rezystancji elementów akumulatora R_i (Ω), napięcia na zaciskach baterii superkondensatorów U_{Ct} (V), rezystancji baterii superkondensatorów R_C (Ω), oraz ilości paliwa spalanego przez APU \dot{m} (kg/s). Cena paliwa oraz energii elektrycznej została

kolejno opisana przez A_f i A_E . $X(k)$ oraz $U(k)$ opisują kolejno stan pojazdu w chwili k oraz zmienne sterujące. Można je opisać jako [11]:

$$\begin{cases} X(k) = [BSoC(k), USoC(k), U_D(k), P_{APU}(k)] \\ U(k) = [A_C(k), i_L(k)] \end{cases} \quad (15)$$

Oznaczenia w powyższym zestawie równań pokrywają się z oznaczeniami użytymi w tym rozdziale, ponadto jako $P_{APU}(k)$ oznaczono energię dostarczaną w chwili k z APU (W), zaś jako $A_C(k)$ oznaczono stopień uruchomienia APU (0-1). Zmienna $A_C(k)$ jest pochodną $P_{APU}(k)$. Z tego powodu główną zmienną decyzyjną jest prąd rozładowania akumulatorów $i_L(k)$. Aby możliwe było bezpieczne stosowanie algorytmu, zastosowano szereg dodatkowych ograniczeń. Związane są one z maksymalnym możliwym zakresem parametrów przyjmowanych przez zmienne stanu i zmienną decyzyjną. Zakresy te wynikają z budowy poszczególnych elementów pojazdu oraz względów bezpieczeństwa. Opisane mogą być one za pomocą poniższych równań [11]:

$$\begin{cases} BSoC_{min} \leq BSoC(k) \leq BSoC_{max} \\ USoC_{min} \leq USoC(k) \leq USoC_{max} \\ i_{L,min} \leq i_L(k) \leq i_{L,max} \\ i_{C,min} \leq i_C(k) \leq i_{C,max} \\ P_{APU,min} \leq P_{APU} \leq P_{APU,max} \end{cases} \quad (16)$$

Gdzie: $BSoC_{min}$ i $BSoC_{max}$ oznaczają kolejno minimalny i maksymalny dozwolony poziom naładowania akumulatorów, przyjęte kolejno jako 0,2 i 1. Minimalny i maksymalny poziom naładowania superkondensatorów oznaczono kolejno jako $USoC_{min}$ i $USoC_{max}$, zaś jako ich wartości przyjęto kolejno 0,5 i 1. Minimalne (rozumiane jako maksymalne natężenie prądu ładowania akumulatorów) i maksymalne natężenie prądu rozładowania akumulatorów, oznaczono kolejno jako $i_{L,min}$ i $i_{L,max}$, a za ich wartości przyjęto -154A i 154A. Analogicznie minimalną wartość natężenia prądu rozładowania superkondensatorów (analogicznie rozumianą jako maksymalne natężenie prądu ładowania) oznaczono jako $i_{C,min}$, zaś maksymalną jako $i_{C,max}$. Wartości tych parametrów są znacznie wyższe dla superkondensatorów i wynoszą kolejno -500 A i 500 A. Minimalną wartość mocy wytwarzanej przez APU oznaczono jako $P_{APU,min}$, zaś moc maksymalną jako $P_{APU,max}$. Wartości tych parametrów wynoszą kolejno 0 i 75 kW.


5 Określanie parametrów modelu i badanie ich wpływu na wyniki symulacji

W poprzednich rozdziałach opisano ogólny sposób działania zaproponowanej metody oraz określono dokładnie działanie poszczególnych algorytmów wchodzących w skład metody. Bieżący rozdział skupia się na określeniu dokładnych parametrów poszczególnych algorytmów. Oprócz wyników, w rozdziale tym opisano także szczegółowo sposób ich uzyskiwania. W niniejszej rozprawie przyjęto metodykę, zgodnie z którą parametry poszczególnych algorytmów obliczane były oddzielnie, tak by oddzielić wpływ poszczególnych parametrów na działanie proponowanej metody od wpływu parametrów sterujących dla innych algorytmów. Podejście to jest zgodne z zasadą superpozycji. Weryfikacja metody została przedstawiona w kolejnym rozdziale niniejszej rozprawy.


5.1 Metodyka generowania wiarygodnych profili prędkości

Jednym z istotnych problemów przy tworzeniu i testowaniu metod zarządzania energią w pojazdach *HEV* jest brak wiarygodnych profili prędkości, które mogłyby posłużyć do testowania nowych metod bądź optymalizacji parametrów metod już istniejących. Aby takie dane były w pełni wiarygodne musiałyby one pochodzić z rzeczywistych przejazdów pojazdami podobnej klasy. Dodatkowo musiałyby one uwzględniać takie czynniki jak: zróżnicowany temperament kierowcy, różne miejsca zamieszkania kierowców czy przejazdy po zróżnicowanych trasach. Takie badania są bardzo kosztowne i czasochłonne. Najczęściej w literaturze można spotkać wykorzystanie do badań już istniejących, ustandaryzowanych profili prędkości pojazdów. Profile prędkości tego typu można podzielić na 2 grupy. Do pierwszej z nich należą profile sztuczne, które charakteryzują się prostym przebiegiem, stałymi prędkościami i przebiegami. Wykorzystywane są one do określania energochłonności pojazdów oraz spalania i emisji spalin [137]. W tym charakterze sprawdzają się one dobrze, gdyż stanowią prostą i powtarzalną bazę porównawczą. Należą do nich takie profile prędkości, jak EUDC, NEDC czy SORT. Pomimo, że profile te sprawdzają się dobrze w roli kryterium porównawczego dla energochłonności pojazdów, to ze względu na swą prostotę i nierzeczywisty charakter, nie nadają się one do zastosowania jako profile porównawcze, w przypadku bardziej zaawansowanych metod zarządzania energią w pojazdach *HEV*. Tym bardziej nie należy ich wykorzystywać jako profili służących do kalibracji parametrów sterujących dla poszczególnych algorytmów [138]. Przykładowy profil z tej kategorii - NEDC zamieszczono na Rys. 14 [5, 137]. Do drugiej grupy należą profile prędkości uzyskane na podstawie rzeczywistych danych. Choć są utworzone w sposób sztuczny, oddają jednak realistyczne warunki jazdy. Dzieje się tak, ponieważ są one tworzone na podstawie rzeczywistych profili prędkości rejestrowanych w normalnie użytkowanych pojazdach [18]. Profile prędkości tego typu nadają się znacznie lepiej jako wzorce, względem których porównuje się poszczególne metody zarządzania energią w pojazdach *HEV*. Należą do nich, między

innymi, takie profile prędkości jak: Manhattan, HWFET, FTP-75, czy cykle WLTC, WLTP czy Artemis [18]. Przykładem takiego profilu prędkości jest WLTP [139], zaprezentowany na Rys. 15. Pomimo istnienia takich profili, ich liczba jest ograniczona. Dodatkowo przedstawiają one różne sytuacje drogowe w 1 profilu prędkości, co utrudnia kalibrację parametrów dla konkretnych, wybranych profili prędkości. Z tego powodu zdecydowano się na utworzenie sztucznych profili prędkości, które posłużyłyby do kalibracji parametrów algorytmów wchodzących w skład proponowanej metody zarządzania energią w *PHEV*.



Rys. 14 Profil prędkości NEDC [5, 137]



Rys. 15 Profil prędkości WLTP [139]

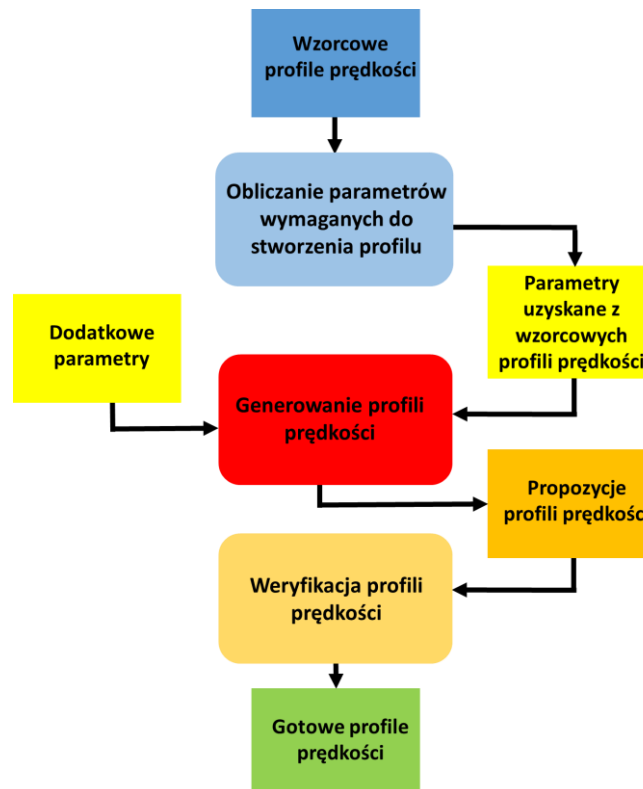
5.1.1 Znane z literatury sposoby generowania sztucznych profili prędkości

W literaturze opisano kilka sposobów i metod generowania sztucznych profili prędkości, w większości w kontekście testów emisji spalin. Jedno z najstarszych podejść do tematu zostało opisane w [140]. W podejściu tym profil prędkości tworzony jest jako łańcuch „mikro podróży”. „Mikro podróż” została zdefiniowana jako prowadzenie pojazdu pomiędzy postojami, wliczając w to okres bezczynności na postoju. Same profile „mikro podróży” wybierane są z istniejących danych, w taki sposób by nowy utworzony cykl prędkości ściśle odpowiadał charakterystyce tworzonych profili prędkości. Podejście to zostało skrytykowane w pracy [141], jako nie odzwierciedlające stochastycznej natury danych i nie oddającej w wystarczającym stopniu zmienności związanej z prowadzeniem pojazdu. W artykule zaproponowano inne podejście, w którym oparto się na łańcuchach Markowa. W podejściu tym

wykorzystano 4 główne bloki, przy czym wyjście każdego z nich jest wejściem do kolejnego bloku. Pierwszy z nich dzieli profil prędkości na pojedyncze zdarzenia, do których należą: przejazd (ang. *cruising*), postój, przyspieszenie i hamownie. W kolejnym bloku następuje określenie prawdopodobieństwa przejścia pomiędzy wszystkimi parami zdarzeń, w wyniku czego powstaje macierz przejścia. W trzecim bloku następuje utworzenie profili prędkości, na podstawie prawdopodobieństwa przejścia pomiędzy poszczególnymi zdarzeniami. W ostatnim bloku następuje selekcja profili prędkości, które spełniają zadane charakterystyki i parametry. W pracy [142] zastosowano podobne podejście, również bazujące na łańcuchach Markowa. Autorzy w swojej pracy dodatkowo uwzględnili nachylenie drogi. Zupełnie innym podejściem kierowano się w pracy [143]. Autorzy założyli, że profil prędkości może zostać wygenerowany jako wyjście systemu liniowego. We wspomnianym artykule autorzy wykorzystali model *ARMA*, przy czym wejściem do modelu był biały szum, symulujący zmienne warunki drogowe, zaś wyjściem prędkość pojazdu. W modelu istotna jest zgodność widma częstotliwości i dystrybuanty prędkości tworzonego profilu prędkości z profilem wzorcowym. Artykuł [144] przedstawia tworzenie profilu prędkości dla śmieciarki, bazując na dystrybuancie parametrów jej trasy. Przypadek ten jest szczególny ze względu na bardzo dużą liczbę przystanków potrzebnych na zbiórkę odpadów. Do parametrów określających profil prędkości zaliczyć można: prędkość dla różnych faz pracy (zbiórka odpadów, powrót z wysypiska do bazy itd.), nachylenie drogi, czas zbiórki odpadów, odległości pomiędzy miejscami zbiórki odpadów, bazą i wysypiskiem oraz pomiędzy bazą a pierwszym z domów. W modelu uwzględniono także wzrost masy śmieciarki, wraz z wzrostem ilości zebranych odpadów, których masa także stanowiła jeden z parametrów. W modelu założono, że rozkład prawdopodobieństwa wystąpienia poszczególnych wartości parametrów jest normalny, z uwzględnieniem granic, których parametry te nie mogły przekroczyć. Kolejna praca [138] stanowi swoiste połączenie wyżej wspomnianych prac. Opisany w artykule profil prędkości składa się kolejno z różnych scenariuszy jazdy, reprezentujących różne warunki ruchu, na które składają się różne „podróże”. Każda „podróż” składa się z fazy przyspieszania, przejazdu, hamowania oraz postoju. Proces generowania poszczególnych „podróży” trwa aż do wyczerpania czasu trwania scenariusza, zaś proces generowania kolejnych scenariuszy trwa aż do wyczerpania czasu trwania generowanego profilu prędkości. Wszystkie parametry zarówno profilu prędkości, jak i poszczególnych scenariuszy i „podróży” podlegają losowaniu zgodnie z założonym rozkładem prawdopodobieństwa. Rozkład ten może być zarówno założony a priori lub być wyznaczony na podstawie rzeczywistych, zarejestrowanych przez pojazd profili prędkości. Parametry określające sam przejazd oprócz średniej prędkości zawierają także tzw. szum. Szum podzielony został na różne zakresy częstotliwości, a każda z nich składa się z sygnału poliharmonicznego złożonego z sumy 3 sygnałów harmonicznym.

5.1.2 Metoda tworzenia sztucznych profili prędkości

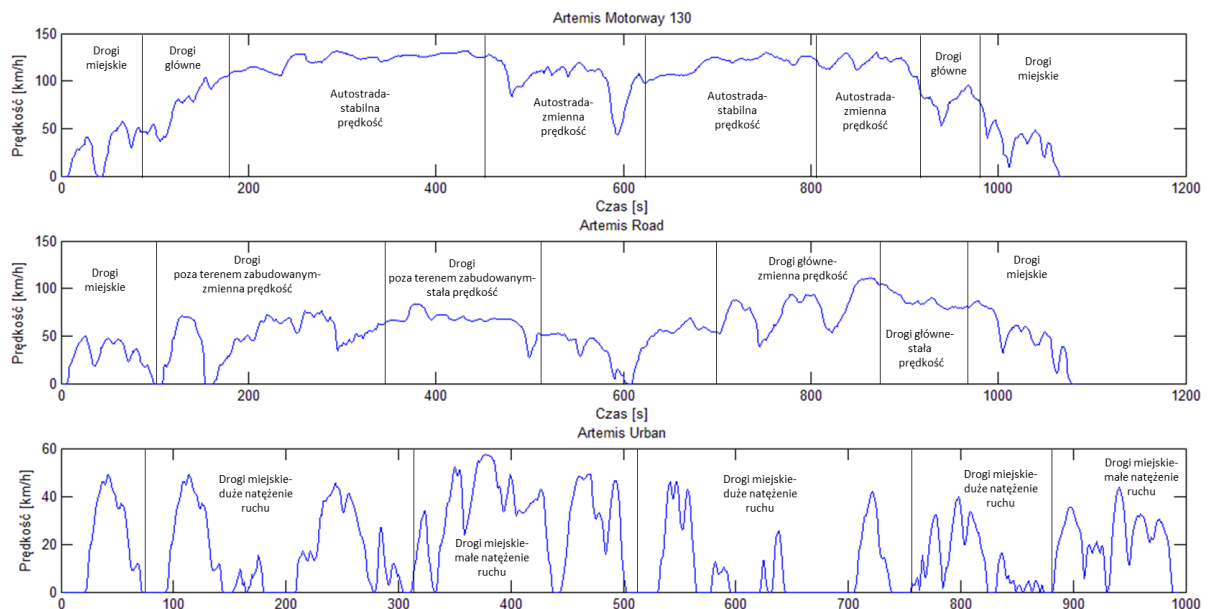
W niniejszej rozprawie problem braku odpowiednich profili prędkości rozwiązano poprzez opracowanie metody do tworzenia sztucznych profili prędkości o odpowiednich, wymaganych parametrach. Budując model skorzystano z doświadczeń opisanych we wcześniejszym podrozdziale. Przy tworzeniu modelu wzorowano się głównie na metodyce opisanej w [138], jednak wprowadzono także elementy innych metod opisanych w literaturze. Schemat metody wykorzystanej w niniejszej rozprawie pokazano na Rys. 16.



Rys. 16 Schemat metody tworzenia sztucznych profili prędkości

Pierwszym etapem, w przedstawionej metodzie, jest obliczanie parametrów, na podstawie których możliwe jest generowanie profilu prędkości. Parametry, o których mowa, podawane są w postaci dystrybuant, zaś sam proces generowania profili ma charakter stochastyczny. Oprócz parametrów uzyskanych z wzorcowych profili prędkości, do algorytmu generującego profile prędkości wprowadzono dodatkowe parametry, które założono a priori. Parametry te podawane są również w formie dystrybuant. Ich dokładna lista została przedstawiona w kolejnej części niniejszego podrozdziału. Profile utworzone na podstawie algorytmu do generowania profili prędkości są następnie weryfikowane w celu odrzucenia profili, które nie mają fizycznej interpretacji. Dotyczy to przykładowo sytuacji, w których zostaje przekroczona dopuszczalna prędkość pojazdu, maksymalna moc pojazdu podczas przyspieszania itd. Weryfikacja jest konieczna ze względu na losowy charakter generowanych profili prędkości.

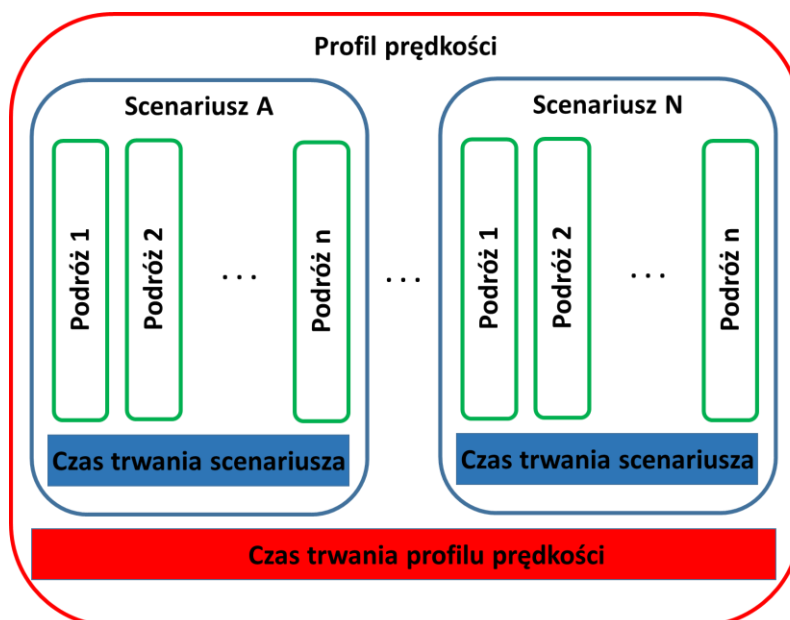
Jako wzorcowe profile, na podstawie których obliczono dystrybuanty wymaganych parametrów, wybrano profile prędkości Artemis [18], które zawierały w sobie 8 różnych rodzajów wzorców jazdy, do których należą: przejazd po autostradzie ze stałą prędkością, przejazd po autostradzie w zmiennych warunkach, przejazd po głównych drogach ze stałą prędkością i przy zmiennych warunkach, przejazd drogami poza terenem zabudowanym ze stałą prędkością i przy zmiennych warunkach oraz przejazd przez tereny miejskie w przypadku niskiego ruchu, w warunkach przeciążenia ruchem samochodowym[18]. Wzorcowe profile prędkości Artemis zostały przedstawione na Rys. 17 [18]. Użyta w rozprawie metoda tworzenia sztucznych profili prędkości może zostać, z powodzeniem, zastosowana do innych przypadków. Wzorcowe profile prędkości wykorzystane do obliczania parametrów dla algorytmu generującego mogą pochodzić z rzeczywistych przejazdów, co pozwala na zastosowanie metody dla konkretnych warunków, w jakich będzie pracować pojazd, dla którego profil prędkości jest tworzony. Umożliwia to uwzględnienie specyfiki danego terenu i natężenia ruchu, jak i specyfiki samego pojazdu.



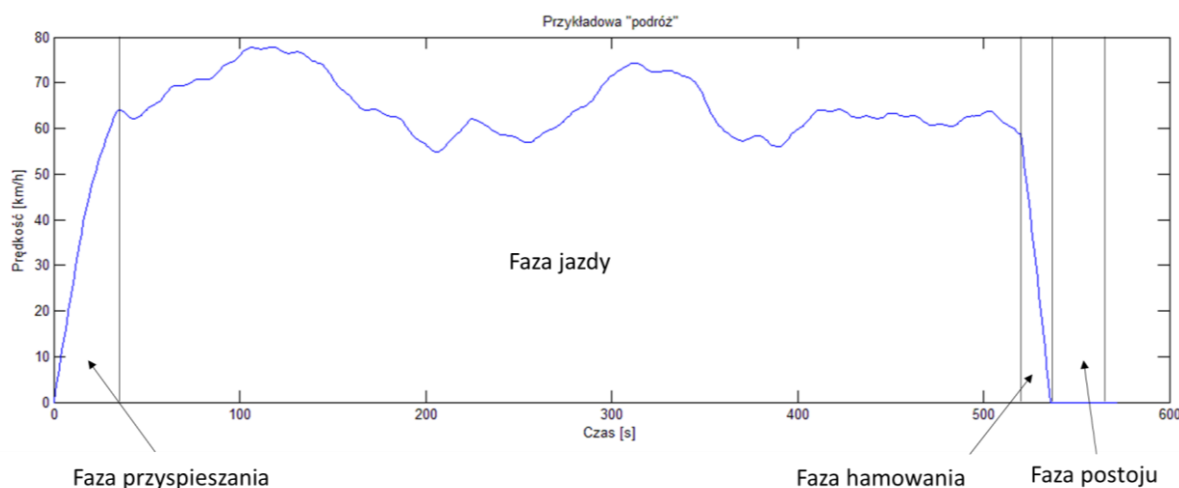
Rys. 17 Profile prędkości Artemis [18]

Algorytm generowania sztucznych profili prędkości został utworzony analogicznie do algorytmu przedstawionego w pracy [138]. Pojedynczy profil prędkości składa się z pojedynczego bądź kilku scenariuszy jazdy. Każdy ze scenariuszy składa się z kolei z jednej bądź kilku „podróży”. Schemat pojedynczego profilu prędkości został przedstawiony na Rys. 18. Pojedyncza podróż składa się zawsze z czterech faz. Należą do nich faza przyspieszania, faza jazdy, faza hamowania i faza postoju. Schemat pojedynczej podróży został przedstawiony na Rys. 19. Poszczególne fazy są charakteryzowane przez odpowiadające im parametry w formie dystrybuanty. Parametry dla konkretnych podróży są losowane, zgodnie z założonymi rozkładami prawdopodobieństwa. Dla profilu prędkości jedynym, losowanym parametrem jest czas trwania profilu, który określa minimalny czas trwania profilu prędkości, po

osiągnięciu którego algorytm zakończy działanie. Dla pojedynczego scenariusza najważniejszym losowym parametrem jest typ scenariusza, jaki będzie realizowany. Następnie, w zależności od wylosowanego scenariusza jazdy, następuje losowanie minimalnego czasu trwania scenariusza, po osiągnięciu którego tworzenie scenariusza zostanie przerwane i następuje tworzenie kolejnej części profilu prędkości, w ramach nowego scenariusza jazdy, bądź zakończenie tworzenia profilu prędkości.



Rys. 18 Schemat budowy profilu prędkości



Rys. 19 Pojedyncza „podróż”

Dystrybuanty parametrów losowanych, w celu wygenerowania pojedynczej „podróż”, zostały podzielone na parametry określające poszczególne jej fazy. Fazy przyspieszania i hamowania są określone przez pojedyncze parametry określające stałe przyspieszenie acc i opóźnienie $dacc$ [138]. Prędkości określające początek i koniec fazy hamowania i przyspieszania, określone są na podstawie prędkości końca fazy poprzedzającej i prędkości początku fazy następującej po fazie hamowania lub przyspieszania. Dodatkowo dla fazy określono maksymalną moc podczas przyspieszania. Wynika ona

z mocy możliwej do uzyskania w przypadku niskiego *SOC* akumulatorów i superkondensatorów. Poziom ten P_{max} ustalono na 150kW. Rozkład prawdopodobieństwa dla *acc* i *dacc* jest rozkładem normalnym, dla każdego z 8 scenariuszy jazdy, zaś parametry rozkładu zostały dobrane a priori, wzorując się na danych odnośnie tych parametrów z [18] i uwzględniając inny charakter pojazdu, dla którego przygotowywany był profil prędkości. Faza postoju, w przypadku gdy prędkość pojazdu wynosi 0 km/h, określona jest poprzez rozkład pojedynczego parametru, określającego czas postoju t_{idle} . W stosunku do koncepcji przedstawionej w [138], postanowiono dodać możliwość, w której prędkość w fazie postoju jedynie gwałtownie spada, nie osiągając poziomu 0 km/h. Odpowiada to sytuacji, w której następuje nagłe hamowanie wymuszone sytuacją na drodze, jednak całkowite zatrzymanie nie jest konieczne. W wypadku wylosowania tej opcji, dla fazy postoju występują 2 parametry opisujące prędkość pojazdu podczas tej fazy v_{idle} oraz czas trwania fazy t_{vidle} . Rozkład parametrów v_{idle} oraz t_{vidle} ma charakter normalny a jego parametry określono a priori, przy czym czas t_{vidle} jest znacznie krótszy niż w przypadku t_{idle} .

Najbardziej istotne i wymagające największego nakładu pracy, okazało się, określenie parametrów związanych z fazą jazdy. Należą do nich: prędkość średnia v_{mean} , czas trwania fazy jazdy t_{drive} oraz parametry określające zmianę prędkości w czasie trwania jazdy. Zmianę prędkości pojazdu, w stosunku do średniej prędkości podczas danej jazdy v_{mean} , nazwano „szumem jazdy” w celu oddzielenia tej części od pozostałych parametrów. Parametry v_{mean} oraz t_{drive} mają charakter normalny i zostały określone a priori bazując na [18]. Dodatkowo uwzględniono maksymalną prędkość dla ciężarówki, wynoszącą 80 km/h [11]

„Szum jazdy”, został określony jako sygnał poliharmoniczny, składający się z 3 sygnałów poliharmonicznych [138]. Każdy z 3 sygnałów poliharmonicznych reprezentuje inną składową zmiennych warunków jazdy i składa się z sygnałów harmonicznych. Każdy z sygnałów harmonicznych określony jest poprzez: amplitudę A , częstotliwość f i przesunięcie fazowe φ . Wartość sygnału poliharmonicznego, reprezentującego pojedynczą składową sytuację drogową może zostać określona dla dowolnego czasu t , zgodnie ze wzorem:

$$s(t) = \sum_{i=1}^3 (A_i * \sin(2\pi f_i + \varphi_i)) \quad (17)$$

Składowe „szumu jazdy” zostały określone jako [138]:

- Szum niskoczęstotliwościowy (0 - 0,01Hz) – określający topografię terenu, natężenie ruchu, ograniczenia prędkości, ukształtowanie drogi itd.
- Szum średniczęstotliwościowy (0,01 - 0,25Hz) – reprezentujący topografię drogi, ogólną prędkość ruchu pojazdów na trasie, charakter prowadzenia pojazdu przez kierowcę itd.
- Szum wysokoczęstotliwościowy (0,25 - 0,5Hz) – określający stan nawierzchni, manewry na drodze takie jak zmiana pasa ruchu, spontaniczne reakcje kierowcy itd.

Rozkład prawdopodobieństwa parametrów dla poszczególnych szumów został dobrany jako rozkład prawdopodobieństwa dla parametrów zidentyfikowanych na podstawie fragmentów profili prędkości Artemis, dla odpowiadających im scenariuszy jazdy podczas fazy przejazdu. Poszczególne scenariusze jazdy Artemis zostały podzielone przez ruchome okna czasowe o długości 50s i przesunięciu 5s. Tak podzielone scenariusze jazdy pozwoliły na zwiększenie ilości krótkich profili prędkości, których parametry mogą zostać zidentyfikowane, co pozwala na dokładniejszą identyfikację rozkładu prawdopodobieństwa dla poszczególnych parametrów. W przypadku gdy parametry miałyby podlegać identyfikacji na podstawie innych, rzeczywistych profili prędkości, można postąpić analogicznie lub zmodyfikować parametry okna czasowego. Identyfikacja parametrów przebiegała według następującej kolejności [138]:

1. Obliczenie średniej wartości prędkości dla fragmentu profilu prędkości, następnie odjęcie wartości średniej prędkości od prędkości chwilowej dla całego fragmentu profilu prędkości.
2. Identyfikacja parametrów szumu niskoczęstotliwościowego, na podstawie wartości sygnału uzyskanego w kroku 1, a następnie odjęcie szumu od wyników uzyskanych w kroku 1.
3. Identyfikacja parametrów szumu średniczęstotliwościowego, na podstawie wartości sygnału uzyskanego w kroku 2, a następnie odjęcie szumu od wyników uzyskanych w kroku 2.
4. Identyfikacja parametrów szumu wysokoczęstotliwościowego, na podstawie wartości sygnału uzyskanego w kroku 3.

Wyniki uzyskane podczas takiej stopniowej identyfikacji parametrów po ponownym złożeniu, bardzo wiernie oddają profil prędkości, będący bazą do identyfikacji parametrów szumu. Sama identyfikacja w przypadku pracy [138] odbywała się z wykorzystaniem nieliniowej metody najmniejszych kwadratów. Jednak w wyniku prac metoda ta okazała się mało efektywna i niedokładna. Z tego powodu zdecydowano się na zmianę nieliniowej metody najmniejszych kwadratów na algorytm genetyczny, którego zadaniem była identyfikacja 9 parametrów dla sygnałów harmonicznym określających szum. Metoda ta okazała się znacznie dokładniejsza i pozwoliła na znacznie lepszą identyfikację parametrów szumu. Funkcja celu została opisana następującym wzorem:


$$J = \sum_{i=1}^n (x_{ri} - x_{ei})^2 \quad (18)$$

Gdzie J oznacza funkcję celu, n , długość trwania fragmentu profilu prędkości poddawanego analizie, x_{ri} jest dokładną wartością sygnału, x_{ei} estymowaną przez algorytm genetyczny wartością szumu.

Weryfikacja profili prędkości ma na celu sprawdzenie czy wygenerowany sygnał spełnia podstawowe parametry, w jakich musi zawierać się generowany profil prędkości. Konieczność weryfikacji powstałego profilu prędkości jest wynikiem stochastycznego generowania profilu prędkości. W przypadku, gdy któryś z warunków dla profilu zostanie przekroczony, profil zostaje w całości odrzucony. Do sprawdzanych parametrów zaliczyć można:

- Prędkość, która nie może w żadnym momencie przekroczyć 80km/h, co jest podyktowane ograniczeniem prędkości ciężarówki.
- Przyspieszenia pomiędzy kolejnymi, następującymi po sobie punktami na przebiegu profilu, które nie mogą przekroczyć $0,11 \text{ m/s}^2$, co jest spowodowane konstrukcją ciężarówki.
- Brak występowania w ostatecznym przebiegu sygnału wyraźnej składowej harmonicznej o wysokiej amplitudzie i częstotliwości, powodującej nagłe i regularne zmiany prędkości pojazdu nie występujące w rzeczywistych warunkach.

Na potrzeby tworzonej metody generowania sztucznych profili prędkości, zidentyfikowano lub przyjęto a priori dystrybuanty 161 różnych parametrów, dotyczących 8 różnych scenariuszy jazdy. Przykładowy profil prędkości, wygenerowany za pomocą opracowanej metody został przedstawiony na poniższym rysunku.



Rys. 20 Sztucznie wygenerowany profil prędkości.

5.2 Dobór parametrów algorytmu rozpoznawania wzorców jazdy DPR

Rozpoznawanie wzorców jazdy, w niniejszej rozprawie, odbywa się poprzez porównanie charakterystycznych parametrów profili prędkości z analogicznymi profilami w wzorcowych profilach prędkości. O zaklasyfikowaniu profilu do danej podgrupy decyduje najmniejsza odległość euklidesowa pomiędzy parametrami profilu wzorcowego i badanego. Cała procedura została szerzej omówiona w podrozdziale 4.2. W celu określenia charakterystycznych parametrów dla odpowiednich scenariuszy jazdy, w pierwszej kolejności utworzono profile wzorcowe. Dla każdego scenariusza jazdy utworzono 10 profili prędkości o czasie około 10 min. W każdym profilu prędkości wykorzystywano jedynie pojedynczy scenariusz, zgodny ze scenariuszem, dla którego profil ten był tworzony. Wyróżniono 8 różnych scenariuszy jazdy: przejazd po autostradzie ze stałą prędkością, przejazd po autostradzie w zmiennych warunkach, przejazd po głównych drogach ze stałą prędkością i przy zmiennych warunkach, przejazd drogami poza terenem zabudowanym ze stałą prędkością i przy zmiennych warunkach oraz przejazd przez tereny miejskie w przypadku niskiego ruchu i w warunkach przeciążenia

ruchem samochodowym [18]. Łącznie na potrzebę identyfikacji parametrów wygenerowano 80 sztucznych profili prędkości o pojedynczym scenariuszu jazdy. Metodyka tworzenia sztucznych profili prędkości została dokładnie opisana w podrozdziale 5.1. Jako charakterystyczne parametry wyróżniono: średnią prędkość pojazdu V_{mean} (km/h), maksymalną prędkość pojazdu V_{max} (km/h), maksymalne przyspieszenie pojazdu a_{maxP} (m/s²), średnie przyspieszenie pojazdu a_{meanP} (m/s²), maksymalne a_{maxN} i średnie opóźnienia pojazdu a_{meanN} (m/s²), czas postoju t_{stop} (s) oraz ilość zatrzymań N_{stop} na każde 100s czasu trwania przejazdu. Wyniki identyfikacji charakterystycznych parametrów jazdy przedstawiają tab. 3 i tab. 4. Dodatkowo, w tabeli dodano parametr opisujący łączny czas trwania wszystkich scenariuszy jazdy t (s).

	Autostrada ze stałą prędkością	Autostrada przy zmiennych warunkach	Drogi główne ze stałą prędkością	Drogi główne przy zmiennych warunkach
a_{maxN} (m/s ²)	1,191	1,138	1,348	1,517
a_{maxP} (m/s ²)	0,702	0,698	0,743	0,740
a_{meanN} (m/s ²)	0,127	0,153	0,168	0,263
a_{meanP} (m/s ²),	0,114	0,145	0,154	0,244
N_{stop}	0,339	0,337	0,344	0,493
t_{stop} (s)	3,841	5,034	6,162	8,880
V_{max} (km/h)	79,891	81,398	81,108	81,627
V_{mean} (km/h)	69,377	61,004	61,586	52,828
t (s)	6197,000	5940,000	7855,000	7917,000

Tab. 3 Charakterystyczne parametry dla poszczególnych scenariuszy jazdy – część 1

	Drogi poza terenem zabudowanym ze stałą prędkością	Drogi poza terenem zabudowanym przy zmiennych warunkach	Drogi miejskie w warunkach przeciążenia ruchem samochodowym	Drogi miejskie w warunkach niskiego ruchu
a_{maxN} (m/s ²)	1,483	1,609	1,728	3,062
a_{maxP} (m/s ²)	0,838	1,994	0,852	0,971
a_{meanN} (m/s ²)	0,219	0,318	0,200	0,515
a_{meanP} (m/s ²),	0,220	0,301	0,220	0,428
N_{stop}	0,462	0,548	0,629	1,374
t_{stop} (s)	6,323	13,357	12,917	28,977

V_{max} (km/h)	69,190	73,499	52,389	40,080
V_{mean} (km/h)	47,486	42,316	34,779	15,683
t (s)	7148,000	6940,000	6356,000	6405,000

Tab. 4 Charakterystyczne parametry dla poszczególnych scenariuszy jazdy – część 2

Ponieważ aktualny scenariusz, według którego porusza się pojazd, obliczany jest w sposób ciągły, istotna jest długość okna czasowego, z którego parametry brane są pod uwagę przy identyfikacji profilu prędkości. Aby określić optymalną długość okna, wygenerowano 100 sztucznych profili prędkości trwających około 30 minut każdy. Wygenerowane profile składały się z różnych scenariuszy jazdy. Metodyka tworzenia profili została opisana szczegółowo w podrozdziale 4.2. Założono, że okno może trwać od 5s do 5 min, z możliwą zmiennością 5s. Dało to łącznie 60 możliwych do zastosowania okien czasowych. Następnie, na podstawie zidentyfikowanych parametrów charakterystycznych dla poszczególnych scenariuszy jazdy, dokonano identyfikacji scenariuszy jazdy dla każdego z profili i okien czasowych. Zbiorcze zestawienie wyników, w postaci wartości procentowych sekund, poprawnie zidentyfikowanych scenariuszy, po uśrednieniu dla wszystkich 100 profili prędkości i dla maksymalnej identyfikacji dla pojedynczego profilu prędkości, podano w tab. 5. Dodatkowo średni procent czasu przy poprawnej identyfikacji przedstawiono graficznie, w postaci wykresu.


Długość trwania okna (s)	Poprawna identyfikacja – maksymalna wartość dla pojedynczego profilu (%)	Poprawna identyfikacja – wartość średnia (%)
5	87,60	35,16
10	88,86	36,15
15	89,92	37,15
20	90,98	38,11
25	91,91	38,91
30	92,25	39,66
35	92,51	40,37
40	92,49	41,03
45	92,46	41,66
50	92,43	42,28
55	92,40	42,86
60	92,37	43,35
65	92,34	43,82
70	92,31	44,25
75	92,28	44,62
80	92,25	44,97
85	92,22	45,30
90	92,19	45,60
95	92,16	45,86
100	92,13	46,08

105	91,71	46,26
110	91,29	46,39
115	90,86	46,47
120	90,43	46,54
125	89,99	46,56
130	89,55	46,55
135	89,11	46,52
140	88,67	46,47
145	88,22	46,39
150	87,76	46,31
155	87,31	46,20
160	86,85	46,07
165	86,47	45,91
170	86,40	45,74
175	86,33	45,54
180	86,26	45,35
185	86,18	45,15
190	86,11	44,93
195	86,04	44,71
200	85,96	44,49
205	85,88	44,25
210	85,81	44,00
215	85,73	43,74
220	85,65	43,47
225	85,57	43,21
230	85,49	42,93
235	85,41	42,66
240	85,33	42,38
245	85,24	42,09
250	85,16	41,80
255	85,07	41,51
260	84,99	41,22
265	84,90	40,94
270	84,81	40,65
275	84,77	40,37
280	85,29	40,08
285	85,82	39,78
290	86,36	39,49
295	86,90	39,19
300	87,45	38,91

Tab. 5 Maksymalne i średnie wartości procentowe poprawnie zidentyfikowanych fragmentów profilu prędkości dla różnych okien czasowych

Zarówno z tab. 5, jak i Rys. 21 jasno wynika, że zarówno wartości średnie, jak i maksymalne wartości poprawnej identyfikacji scenariusza jazdy pojedynczego profilu, osiągają maksimum dla pojedynczej długości okna czasowego. Wynoszą one 92,51% długości profilu prędkości dla okna 35 s, przy wartości

maksymalnej i 46,56 % średniej długości profilu prędkości dla okna o długości 125s. Oba wyniki wskazują na wysoki, poprawny procent rozpoznawanego profilu prędkości, zwłaszcza że dotyczy to całych profili prędkości. Jednocześnie istnieją profile, dla których nie udało się poprawnie rozpoznać scenariuszy. W takim przypadku, ze względu na sposób identyfikacji profilu prędkości, rozpoznany profil jest zbliżony do rzeczywistego profilu prędkości. Chcąc rozpoznawać poprawnie scenariusze jazdy z maksymalną możliwą dokładnością dla różnych profili prędkości, określono długość trwania okna czasowego, na podstawie wartości średnich poprawnie zidentyfikowanych scenariuszy jazdy. Ostatecznie dobrana długość okna czasowego wynosi 125s.



Rys. 21 Średni procent poprawnych identyfikacji fragmentów profilu prędkości dla różnych długości okna czasowego

5.3 Dobór i badanie wpływu parametrów programowania dynamicznego

Programowanie dynamiczne jest metodą pozwalającą na otrzymanie dokładnego rozwiązania optymalnego. Jednak ze względu na swój sposób działania, wymaga ona bardzo często wykonania wielu obliczeń. W przypadku optymalizacji zarządzania energią w pojeździe *HEV* konieczna jest kwantyzacja pola możliwych rozwiązań i w ten sposób ograniczenie ilości możliwych przypadków. Wraz ze zwiększeniem się ilości możliwych do przyjęcia stanów, rośnie dokładność rozwiązania optymalnego, ale zwiększa się, wymagany czas obliczeń. W przypadku proponowanej metody zarządzania energią w pojeździe *HEV* dotyczy to także długości okna czasowego, dla którego dokonywana jest predykcja, a następnie wykonywana optymalizacja metodą programowania dynamicznego. W przypadku zwiększenia długości trwania okna czasowego, możliwe jest uzyskanie lepszych, bardziej optymalnych rozwiązań, jednak skutkuje to znacznym zwiększeniem czasu obliczeń. Aby znaleźć optymalny stopień kwantyzacji oraz długości trwania okna czasowego, przeprowadzono szereg optymalizacji z wykorzystaniem programowania dynamicznego, dla 8 różnych profili prędkości reprezentujących różne scenariusze jazdy. Zdecydowano, że początkowy stopień kwantyzacji wyniesie 10, zaś długość trwania

okna czasowego 4. Następnie, zmieniano jedną z tych wartości i sprawdzano uzyskane wyniki. Wszystkie obliczenia wykonywane były z zastosowaniem identycznego oprogramowania i komputerów o identycznej specyfikacji, co umożliwiło porównanie wyników. Przy badaniach zastosowano sterowanie predykcyjne ze strategią przewidującą, tzn. założono, że informacja o przyszłej prędkości pojazdu jest w pełni znana. Pozwala to na badanie wpływu jedynie parametrów programowania dynamicznego. Wyniki badań przedstawiają tab.6 - tab. 13. Aby zwiększyć czytelność wyników, pojedyncza tablica zawiera dane dla pojedynczego scenariusza jazdy. Funkcją celu stanowiła ilość energii zużytej przez pojazd na pokonanie trasy, zgodnie z równaniem 14. Oprócz dokładnej wartości funkcji celu, podano różnice w stosunku do wartości uzyskanej przy stopniu kwantyzacji 10 i długości trwania okna 4s. W przypadku różnicy wynik ujemny oznacza mniejsze zużycie energii. W tabelach 6 - 13 wykorzystano opis skrócony, gdzie pierwsza liczba oznacza długość okna czasowego, zaś druga liczba oznacza stopień kwantyzacji np. 5 - 10. Przez stopień kwantyzacji rozumie się liczbę możliwych wariantów w danym kroku.

Długość okna czasowego – stopień kwantyzacji	Czas obliczeń (s)	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
2 - 10	48,312	29947159,2	413821,461
3 - 10	138,892	29535748,6	2410,91023
4 - 10	1101,042	29533337,7	0
5 - 10	9949,25	29530915,9	-2421,79039
4 - 5	191,972	29941350,9	408013,229
4 - 15	4871,606	29532183	-1154,67292
4 - 20	14765,811	29532429,3	-908,405651

Tab. 6 Wyniki dla scenariusza jazdy po autostradzie ze stałą prędkością.

Długość okna czasowego – stopień kwantyzacji	Czas obliczeń (s)	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
2 - 10	42,786	22280893,7	7457,49775
3 - 10	232,945	22275838,6	2402,39388
4 - 10	1911,974	22273436,2	0
5 - 10	18596,313	22271425,7	-2010,52624
4 - 5	165,352	22276034,1	2597,84647
4 - 15	8874,072	22272555,8	-880,449416
4 - 20	27113,256	22272345,9	-1090,31352

Tab. 7 Wyniki dla scenariusza jazdy po autostradzie przy zmiennych warunkach drogowych.

Długość okna czasowego – stopień kwantyzacji	Czas obliczeń (s)	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
2 - 10	48,155	29947159,2	5913,79641
3 - 10	252,808	29943247,7	2002,36929
4 - 10	2153,1	29941245,4	0
5 - 10	19823,382	29938859,6	-2385,79165
4 - 5	184,575	29941350,9	105,564852
4 - 15	9656,094	29940931	-314,343469
4 - 20	29148,398	29940321,5	-923,815035

Tab. 8 Wyniki dla scenariusza jazdy po drogach głównych ze stałą prędkością.

Długość okna czasowego – stopień kwantyzacji	Czas obliczeń (s)	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
2 - 10	47,06	11070562,1	295592,093
3 - 10	291,477	10922355,8	147385,879
4 - 10	2596,882	10774970	0
5 - 10	25239,818	10625906,8	-149063,192
4 - 5	213,637	10773391,4	-1578,51388
4 - 15	12201,059	10774600,2	-369,757394
4 - 20	37101,617	10774083,4	-886,517764

Tab. 9 Wyniki dla scenariusza jazdy po drogach głównych przy zmiennych warunkach drogowych.

Długość okna czasowego – stopień kwantyzacji	Czas obliczeń (s)	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
2 - 10	41,55	20712831,1	633,818481
3 - 10	211,784	20711899,5	-297,790412
4 - 10	1709,205	20712197,3	0
5 - 10	15796,455	20712307,2	109,90881
4 - 5	165,187	20714220,5	2023,16589
4 - 15	7706,157	20711652,4	-544,959305
4 - 20	23156,631	20711141,3	-1056,03011

Tab. 10 Wyniki dla scenariusza jazdy po drogach poza terenem zabudowanym ze stałą prędkością.

Długość okna czasowego – stopień kwantyzacji	Czas obliczeń (s)	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
2 - 10	43,953	4062414,61	4151,90032
3 - 10	313,162	4059541,84	1279,12506
4 - 10	2888,851	4058262,71	0
5 - 10	27788,458	4058894,57	631,864756
4 - 5	236,328	4062926,61	4663,90079

4 - 15	13908,674	4058312,28	49,5706543
4 - 20	41101,142	4057882,3	-380,414017

Tab. 11 Wyniki dla scenariusza jazdy po drogach poza terenem zabudowanym przy zmiennych warunkach jazdy.

Długość okna czasowego – stopień kwantyzacji	Czas obliczeń (s)	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
2 - 10	48,155	29947159,2	5913,79641
3 - 10	252,808	29943247,7	2002,36929
4 - 10	2153,1	29941245,4	0
5 - 10	19823,382	29938859,6	-2385,79165
4 - 5	184,575	29941350,9	105,564852
4 - 15	9656,094	29940931	-314,343469
4 - 20	29148,398	29940321,5	-923,815035

Tab. 12 Wyniki dla scenariusza jazdy po drogach miejskich przy przeciążeniu ruchem drogowym.

Długość okna czasowego – stopień kwantyzacji	Czas obliczeń (s)	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
2 - 10	46,799	12155475,8	-99,9756306
3 - 10	278,551	12155135	-440,756443
4 - 10	2356,374	12155575,7	0
5 - 10	22097,282	12156237,5	661,71712
4 - 5	219,385	12156013,9	438,171897
4 - 15	10903,081	12154489,8	-1085,93958
4 - 20	32921,604	12154517	-1058,75477

Tab. 13 Wyniki dla scenariusza jazdy po drogach miejskich przy swobodnym przejeździe.

W zdecydowanej większości przypadków, zwiększenie stopnia kwantyzacji przyczyniło się do uzyskania lepszych wyników, podobnie jak zwiększenie długości okna czasowego, dla którego przeprowadzono obliczenia. W każdym z badanych przypadków, zwiększenie długości trwania okna czasowego i stopnia kwantyzacji, przyczyniło się do znacznego zwiększenia długości trwania obliczeń. Należy przy tym zauważyć, że zwiększenie czasu obliczeń jest porównywalne pomiędzy różnymi profilami prędkości, natomiast zmniejszenie wartości funkcji celu zależy silnie od rodzaju scenariusza jazdy, z którym mamy do czynienia. Największe różnice występują w przypadku scenariusza jazdy po drogach głównych ze zmienną prędkością. Najmniejsze różnice występują w przypadku jazdy miejskiej, w warunkach przeciążenia ruchem drogowym. Niekorzystne różnice wyników rosną skokowo przy zmniejszaniu długości trwania okna czasowego do 3 s. Czas trwania scenariuszy wynosił około 10 minut. Uniemożliwia to prowadzenie obliczeń dla części konfiguracji online. Możliwe jest prowadzenie obliczeń na bardziej wydajnych komputerach oraz optymalizacja kodu oprogramowania, co może znacznie ograniczyć czas obliczeń. Nie jest to jednak przedmiotem niniejszej rozprawy doktorskiej. Aby

umożliwić optymalne wykorzystanie czasu pozostającego do dyspozycji w przypadku optymalizacji online, tak aby był on porównywalny z długością trwania konkretnego przejazdu, zdecydowano o przeprowadzeniu obliczeń dla konfiguracji 3s okna czasowego i stopnia kwantyzacji 12 oraz 4s okna czasowego oraz stopnia kwantyzacji równego 7. Wyniki zamieszczono zbiorczo dla wszystkich badanych profili prędkości w tab. 14-15. W poniższych tabelach numery profili prędkości oznaczają: 1 - profil dla scenariusza jazdy po autostradzie ze stałą prędkością, 2 - profil dla scenariusza jazdy po autostradzie przy zmiennych warunkach drogowych, 3 - profil dla scenariusza jazdy po drogach głównych ze stałą prędkością, 4 - profil dla scenariusza jazdy po drogach głównych przy zmiennych warunkach drogowych, 5 - profil dla scenariusza jazdy po drogach poza terenem zabudowanym ze stałą prędkością, 6 - profil dla scenariusza jazdy po drogach poza terenem zabudowanym przy zmiennych warunkach drogowych, 7 - profil dla scenariusza jazdy po drogach miejskich w warunkach przeciążenia ruchem drogowym, 8 - profil dla scenariusza jazdy po drogach miejskich przy umiarkowanym ruchu drogowym.

Profil prędkości	Czas obliczeń (s)	Różnica czasu obliczeń badanej konfiguracji parametrów i konfiguracji 4-10	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
1	227,624	-873,418	29534677,1	1339,3778
2	384,308	-1527,666	22276545,5	3109,27737
3	410,69	-1742,41	29943522,8	2277,48184
4	490,033	-2106,849	10921789,6	146819,631
5	361,123	-1348,082	20711817,5	-379,804986
6	522,879	-2365,972	4059332,72	1070,01256
7	735,655	-3204,475	4216109,67	1533,00653
8	461,229	-1895,145	12154288,4	-1287,31748

Tab. 14 Wyniki dla konfiguracji 3s okna czasowego i stopnia kwantyzacji 12

Profil prędkości	Czas obliczeń (s)	Różnica czasu obliczeń badanej konfiguracji parametrów i konfiguracji 4-10	Wartość funkcji celu	Różnica wartości funkcji celu badanej konfiguracji parametrów i konfiguracji 4-10
1	294,989	-806,053	29533033	-304,679141
2	519,905	-1392,069	22273954,7	518,474216
3	565,344	-1587,756	29941368	122,635501
4	698,898	-1897,984	10775158,5	188,546898
5	481,979	-1227,226	20711962,2	-235,131067
6	739,222	-2149,629	4058971,58	708,872045
7	1031,429	-2908,701	4216951,59	2374,92239
8	658,253	-1698,121	12154891,4	-684,364974

Tab. 15 Wyniki dla konfiguracji 4s okna czasowego i stopnia kwantyzacji 7

W związku z dłuższym czasem obliczeń dla konfiguracji 4s okno czasowe oraz stopniem kwantyzacji 7, ostatecznie zdecydowano o zastosowaniu programowania dynamicznego, z oknem czasowym wynoszącym 3 s oraz stopniem kwantyzacji 12.

5.4 Dobór parametrów sterowania predykcyjnego

W niniejszej rozprawie doktorskiej, zdecydowano o użyciu sterowania predykcyjnego zmiennego eksponentalnie. Dokładny opis zastosowanej metody przedstawiono w podrozdziale 4.3. W odniesieniu do sterowania predykcyjnego istotny jest dobór parametru sterującego ε , zgodnie z równaniem 6. W tym celu wykonano szereg optymalizacji metodą symulowanego wyżarzania SA. Zadaniem optymalizacji było znalezienie takiego parametru ε , aby wartość predykcji prędkości jak najbardziej pokrywała się z rzeczywistą prędkością w konkretnym profilu prędkości. Parametr powinien być uniwersalny w ramach pojedynczego scenariusza jazdy, tak by umożliwiał jak najlepszą predykcję profilu prędkości po rozpoznaniu scenariusza jazdy przez algorytm DPR. W tym celu optymalizację przeprowadzono dla identycznych 80 sztucznych profili prędkości, dla których w podrozdziale 5.2 obliczone zostały parametry wzorcowe DPR poszczególnych scenariuszy jazdy. Pozwala to uogólnić optymalizację poza przypadek pojedynczego profilu prędkości, tak by wynik dotyczył całej grupy profili prędkości reprezentujących pojedynczy scenariusz jazdy. Funkcja celu opisana została równaniem:

$$J_{MPC} = \frac{1}{N} * \sum_{i=1}^N \frac{1}{M} * \sum_{j=1}^M \sqrt{(v_{pij} - v_{i+j})^2} \quad (19)$$

Gdzie: N oznacza długość trwania profilu prędkości (s), M – długość okna czasowego, które podlega predykcji, v_{pij} – przewidywaną prędkość pojazdu w chwili $i + j$, zaś v_{i+j} jest rzeczywistą prędkością pojazdu w chwili $i + j$. Wyniki optymalizacji zostały przedstawione w tab. 16 - 19. W poniższych tabelach numery zestawów scenariuszy reprezentują: 1 - profile prędkości dla scenariuszy jazdy po autostradzie ze stałą prędkością, 2 - profile prędkości dla scenariuszy jazdy po autostradzie przy zmiennych warunkach drogowych, 3 - profile prędkości dla scenariuszy po drogach głównych ze stałą prędkością, 4 - profile prędkości dla scenariuszy jazdy po drogach głównych przy zmiennych warunkach drogowych, 5 - profile prędkości dla scenariuszy jazdy po drogach poza terenem zabudowanym ze stałą prędkością, 6 - profile prędkości dla scenariuszy jazdy po drogach poza terenem zabudowanym przy zmiennych warunkach drogowych, 7 - profile prędkości dla scenariuszy jazdy po drogach miejskich w warunkach przeciążenia ruchem drogowym, 8 - profile prędkości dla scenariuszy po drogach miejskich przy umiarkowanym ruchu drogowym.

Zestaw profili prędkości	Wartość funkcji celu dla profili prędkości reprezentujących scenariusz 1	Wartość parametru ε dla profili prędkości reprezentujących scenariusz 1	Wartość funkcji celu dla profili prędkości reprezentujących scenariusz 2	Wartość parametru ε funkcji celu dla profili prędkości reprezentujących scenariusz 2
1	0,8596	$5,997 \cdot 10^{-5}$	1,0929	$1,636 \cdot 10^{-5}$
2	0,8596	$5,984 \cdot 10^{-5}$	1,0929	$1,636 \cdot 10^{-5}$
3	0,8596	$5,999 \cdot 10^{-5}$	1,0929	$1,648 \cdot 10^{-5}$
4	0,8596	$5,988 \cdot 10^{-5}$	1,0929	$1,644 \cdot 10^{-5}$
5	0,8596	$5,987 \cdot 10^{-5}$	1,0929	$1,642 \cdot 10^{-5}$
6	0,8596	$5,989 \cdot 10^{-5}$	1,0929	$1,676 \cdot 10^{-5}$
7	0,8596	$5,989 \cdot 10^{-5}$	1,0929	$1,639 \cdot 10^{-5}$
8	0,8596	$5,985 \cdot 10^{-5}$	1,0929	$1,633 \cdot 10^{-5}$
9	0,8596	$5,986 \cdot 10^{-5}$	1,0929	$1,642 \cdot 10^{-5}$
10	0,8596	$5,984 \cdot 10^{-5}$	1,0929	$1,646 \cdot 10^{-5}$
Średnio	0,8596	$5,989 \cdot 10^{-5}$	1,0929	$1,644 \cdot 10^{-5}$

Tab. 16 Wyniki optymalizacji dla profili prędkości reprezentujących scenariusz 1 i 2

Zestaw profili prędkości	Wartość funkcji celu dla profili prędkości reprezentujących scenariusz 3	Wartość parametru ε dla profili prędkości reprezentujących scenariusz 3	Wartość funkcji celu dla profili prędkości reprezentujących scenariusz 4	Wartość parametru ε funkcji celu dla profili prędkości reprezentujących scenariusz 4
1	1,1510	$1,630 \cdot 10^{-5}$	1,7766	$-2,798 \cdot 10^{-5}$
2	1,1510	$1,621 \cdot 10^{-5}$	1,7766	$-2,791 \cdot 10^{-5}$
3	1,1510	$1,612 \cdot 10^{-5}$	1,7766	$-2,788 \cdot 10^{-5}$
4	1,1510	$1,620 \cdot 10^{-5}$	1,7766	$-2,769 \cdot 10^{-5}$
5	1,1510	$1,613 \cdot 10^{-5}$	1,7766	$-2,833 \cdot 10^{-5}$
6	1,1510	$1,615 \cdot 10^{-5}$	1,7766	$-2,979 \cdot 10^{-5}$
7	1,1510	$1,610 \cdot 10^{-5}$	1,7766	$-2,637 \cdot 10^{-5}$
8	1,1510	$1,602 \cdot 10^{-5}$	1,7766	$-2,773 \cdot 10^{-5}$
9	1,1510	$1,622 \cdot 10^{-5}$	1,7766	$-2,783 \cdot 10^{-5}$
10	1,1510	$1,636 \cdot 10^{-5}$	1,7766	$-2,787 \cdot 10^{-5}$
Średnio	1,1510	$1,618 \cdot 10^{-5}$	1,7766	$-2,794 \cdot 10^{-5}$

Tab. 17 Wyniki optymalizacji dla profili prędkości reprezentujących scenariusz 3 i 4

Zestaw profili prędkości	Wartość funkcji celu dla profili prędkości reprezentujących scenariusz 5	Wartość parametru ε dla profili prędkości reprezentujących scenariusz 5	Wartość funkcji celu dla profili prędkości reprezentujących scenariusz 6	Wartość parametru ε funkcji celu dla profili prędkości reprezentujących scenariusz 6
1	1,5538	$-2,643 \cdot 10^{-4}$	2,0340	$-5,010 \cdot 10^{-4}$
2	1,5538	$-2,651 \cdot 10^{-4}$	2,0340	$-5,008 \cdot 10^{-4}$
3	1,5538	$-2,642 \cdot 10^{-4}$	2,0340	$-5,007 \cdot 10^{-4}$
4	1,5538	$-2,654 \cdot 10^{-4}$	2,0340	$-5,004 \cdot 10^{-4}$
5	1,5538	$-2,650 \cdot 10^{-4}$	2,0340	$-5,010 \cdot 10^{-4}$
6	1,5538	$-2,636 \cdot 10^{-4}$	2,0340	$-5,008 \cdot 10^{-4}$
7	1,5538	$-2,642 \cdot 10^{-4}$	2,0340	$-5,011 \cdot 10^{-4}$
8	1,5538	$-2,631 \cdot 10^{-4}$	2,0340	$-5,013 \cdot 10^{-4}$

9	1,5538	-2,643*10 ⁻⁴	2,0340	-5,011*10 ⁻⁴
10	1,5538	-2,630*10 ⁻⁴	2,0340	-5,012*10 ⁻⁴
Średnio	1,5538	-2,642*10 ⁻⁴	2,0340	-5,009*10 ⁻⁴

Tab. 18 Wyniki optymalizacji dla profili prędkości reprezentujących scenariusz 5 i 6

Zestaw profili prędkości	Wartość funkcji celu dla profili prędkości reprezentujących scenariusz 7	Wartość parametru ε dla profili prędkości reprezentujących scenariusz 7	Wartość funkcji celu dla profili prędkości reprezentujących scenariusz 8	Wartość parametru ε funkcji celu dla profili prędkości reprezentujących scenariusz 8
1	1,3687	-3,803*10 ⁻⁴	1,3687	-1,611*10 ⁻³
2	1,3687	-3,788*10 ⁻⁴	1,3687	-1,622*10 ⁻³
3	1,3687	-3,785*10 ⁻⁴	1,3687	-1,597*10 ⁻³
4	1,3687	-3,790*10 ⁻⁴	1,3687	-1,614*10 ⁻³
5	1,3687	-3,790*10 ⁻⁴	1,3687	-1,616*10 ⁻³
6	1,3687	-3,786*10 ⁻⁴	1,3687	-1,615*10 ⁻³
7	1,3687	-3,790*10 ⁻⁴	1,3687	-1,611*10 ⁻³
8	1,3687	-3,786*10 ⁻⁴	1,3687	-1,615*10 ⁻³
9	1,3687	-3,769*10 ⁻⁴	1,3687	-1,617*10 ⁻³
10	1,3687	-3,774*10 ⁻⁴	1,3687	-1,610*10 ⁻³
Średnio	1,3687	-3,786*10 ⁻⁴	1,3687	-1,613*10 ⁻³

Tab. 19 Wyniki optymalizacji dla profili prędkości reprezentujących scenariusz 7 i 8

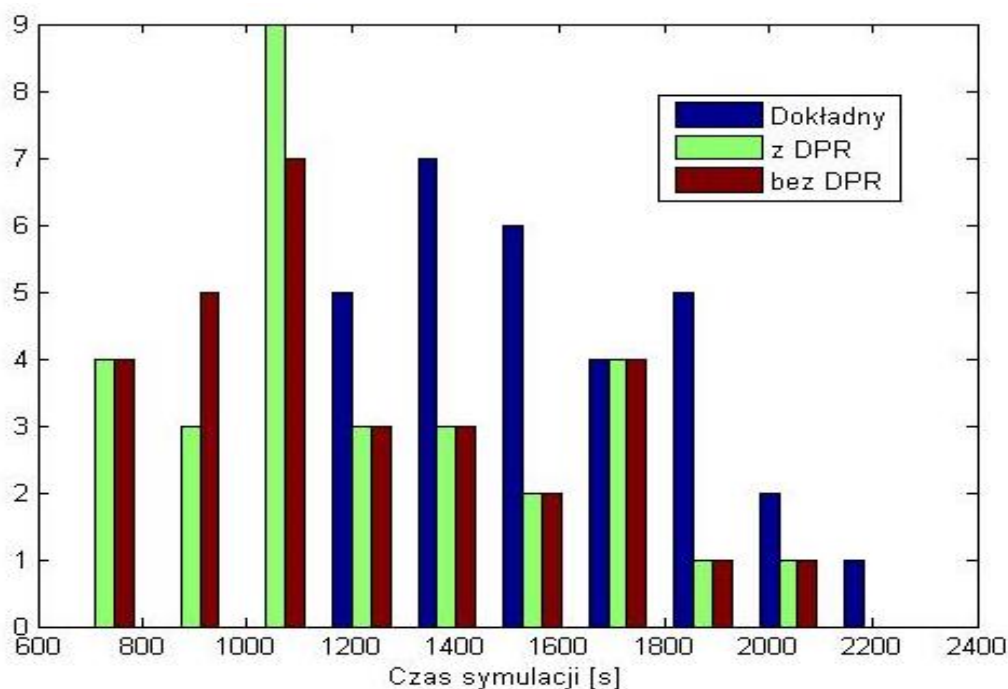
Uzyskane wyniki optymalizacji są bardzo zgodne dla różnych profili prędkości reprezentujących pojedynczy scenariusz jazdy, pomimo że poszczególne profile prędkości różnią się od siebie. Dotyczy to zarówno funkcji celu, jak i wartości samego parametru ε , podlegającego optymalizacji. Potwierdza to słuszność założenia, że optymalne wartości parametru ε zależą od typu scenariusza jazdy, z jakim porusza się pojazd. Ponieważ wyniki były wyjątkowo zgodne, jako obowiązującą wartość parametru ε przyjęto średnią z 10 profili prędkości reprezentujących dany scenariusz jazdy.

6 Badania weryfikacyjne


Proponowana metoda zarządzania energią w pojazdach *HEV* została zweryfikowana poprzez badania weryfikacyjne. W ramach badań, przetestowano proponowaną metodę na 30 losowo wygenerowanych profilach prędkości. Profile zostały utworzone w ramach metody opisanej w podrozdziale 5.1. Profile prędkości trwały około 20 minut i zawierały różne scenariusze jazdy. Dla każdego profilu, oprócz symulacji działania dla proponowanej metody zarządzania energią, przeprowadzono 3 dodatkowe symulacje. Obejmowały one: badanie z wykorzystaniem strategii opartej na regułach oraz dwie modyfikacje proponowanej metody. Dla każdej wykonanej symulacji początkowy poziom naładowania akumulatorów i baterii superkondensatorów był identyczny i wynosił kolejno 0,9 i 0,9. Symulacja przeprowadzona została na identycznych komputerach, co zapewnia możliwość porównania czasu obliczeń dla różnych metod. Strategia oparta o reguły została szczegółowo opisana w podrozdziale 4.1. Jest ona strategią referencyjną, względem której proponowana metoda została oceniona. Jest ona strategią znacznie prostszą i nie wymagającą nakładów obliczeniowych, ale także strategią stałą, która nie dostosowuje się do warunków jazdy. Modyfikacja proponowanej metody polegała na zmianie sposobu działania algorytmu MPC, którego zadaniem jest predykcja prędkości pojazdu, i decyzja o danych wejściowych dla algorytmu programowania dynamicznego *DP*. Pierwsza modyfikacja polegała na zamianie algorytmu *MPC* na strategię przewidyjącą. Ma ona za zadanie sprawdzić jak proponowana strategia sprawdziłaby się w przypadku dokładnej predykcji prędkości. Druga modyfikacja polega na pominięciu algorytmu *DPR* w metodzie i zastosowaniu algorytmu *MPC* ze stałym współczynnikiem ε zgodnie z równaniem 6. Wielkość współczynnika ε wybrano jako średnią dla różnych scenariuszy jazdy, wynoszącą $-3,364 \cdot 10^{-4}$. Funkcja celu została określona przez koszt pokonania trasy zgodnie z równaniem 14. Koszty dla metody wykorzystującej proste reguły zostały policzone w analogiczny sposób. Aby uwzględnić zarówno energię pochodzącą ze spalania paliwa jak i energię elektryczną, zdecydowano się na wyrażenie energochłonności pojazdu w kosztach jego eksploatacji na trasie. Za koszt paliwa A_f przyjęto 5,1 PLN/l, zaś za koszt energii elektrycznej A_E przyjęto 0,75 PLN/kWh. Wyniki badań zostały zaprezentowane w postaci histogramów przedstawiających licznosc wyników symulacji dla pojedynczej wielkości, takiej jak czas trwania symulacji czy wartość funkcji celu. W większości, na pojedynczym histogramie, zaprezentowano zbiorczo wyniki różnych metod. W poniższych histogramach przyjęto następujące oznaczenia: „Dokładna” - oznacza metodę wykorzystującą strategię przewidyjącą, „z DPR” - oznacza proponowaną metodę, „bez DPR” - oznacza metodę bez użycia *DPR* ze stałym współczynnikiem ε dla *MPC*, „Reguły” - oznacza strategię z wykorzystaniem prostych reguł. Na wstępie należy zaznaczyć, że dla 2 profili prędkości nie udało się przeprowadzić symulacji dla metody wykorzystującej proste reguły. Spowodowane było to znacznym przekroczeniem możliwych wartości natężenia prądu elektrycznego dla baterii superkondensatorów. W praktyce oznacza to, że przy użyciu tej strategii nie byłaby możliwa realizacja tego profilu prędkości. W przypadku rzeczywistego pojazdu jest to akceptowalne, gdyż

oznaczałoby to pokonanie trasy z mniejszą prędkością lub mniejszym przyspieszeniem w danym miejscu trasy. W przypadku badań numerycznych eliminuje to daną kombinację strategii i profilu prędkości, uniemożliwiając porównanie z innymi strategiami i wysnucie wniosków. Jednocześnie problem nie występował w przypadku pozostałych trzech strategii. Aby umożliwić porównanie z innymi strategiami, wygenerowano dwa dodatkowe profile prędkości i zastąpiono nimi profile, dla których przeprowadzenie symulacji z użyciem strategii opartej na regułach było niemożliwe. Wyniki badań przedstawiono poniżej.

W pierwszej kolejności skupiono się na czasie symulacji, który przedstawiono na Rys. 22. Ponieważ czasy trwania profili prędkości są różne, co znacząco wpływa na czas symulacji, na Rys. 23 przedstawiono różnice pomiędzy długością profilu prędkości a czasem trwania jego symulacji dla różnych metod. Pozwala to na analizę czasu trwania symulacji niezależnie od czasu trwania samego profilu prędkości. Dodatnia wartość oznacza zapas czasu. Nie uwzględniono czasu trwania symulacji dla strategii z prostymi regułami, gdyż ze względu na bardzo niską złożoność obliczeniową, czas symulacji jest pomijalny, w porównaniu z czasem trwania profilu prędkości. Z histogramów jasno wynika, że czas trwania symulacji, w większości przypadków jest zbliżony do czasu trwania profilu prędkości. Zdarzają się przy tym zarówno scenariusze jazdy, dla których czas trwania symulacji jest znacznie niższy od czasu trwania profilu prędkości, jak i znacznie wyższy od tego czasu. W przypadku strategii przewidującej „Dokładnej”, czas trwania symulacji jest wyraźnie dłuższy niż w przypadku pozostałych metod. Należy przy tym pamiętać, że kod programu nie został zoptymalizowany pod względem szybkości obliczeń i możliwe jest znaczne przyspieszenie obliczeń, na przykład poprzez równoległe przeprowadzanie części obliczeń.



Rys. 22 Histogram czasów trwania symulacji dla różnych metod




Rys. 23 Histogram różnicy czasów trwania profili prędkości i czasów symulacji.

Średnie różnice czasu trwania scenariuszy jazdy i profili prędkości zostały przedstawione w tab. 20.

„Dokładnie”	„z DPR”	„bez DPR”
-372,95 s	-12,66 s	-13,94 s


Tab. 20 Średnie różnice czasu trwania profili prędkości i symulacji



Rys. 24 Histogram kosztów pokonania 100 km dla poszczególnych strategii zarządzania energią w pojeździe.

Kolejną weryfikowaną cechą był koszt pokonania danego profilu prędkości. Aby umożliwić bardziej ogólne wyobrażenie kosztów przejazdu oraz wyeliminowanie czynnika różnicy drogi pokonywanej w poszczególnych profilach prędkości, przedstawiono koszt pokonania 100 km dla poszczególnych metod. Wyniki zostały przedstawione w postaci histogramu na rys. 24.


Na histogramie można zauważyć, że koszty są zbliżone dla różnych strategii, choć cechują się sporą rozpiętością. Jest to spowodowane przez obiektywną ilość energii niezbędną do pokonania przez pojazd trasy z określonym profilem prędkości. Koszty niezbędne do pokonania trasy dominują w stosunku do oszczędności możliwych do poczynienia w związku z zastosowaniem różnych strategii. Aby umożliwić porównanie różnych strategii, porównano koszty uzyskane dla poszczególnych scenariuszy jazdy dla różnych strategii. Pierwsze zestawienie porównuje wyniki innych metod do wyników strategii z użyciem sterowania predykcyjnego przewidującego „Dokładnie”. Na histogramach podano koszty uzyskane dla poszczególnych strategii i dla strategii „Dokładnie”. Na rys. 25 przedstawiono koszty pokonania poszczególnych scenariuszy jazdy, zaś na rys. 26 koszty przy pokonaniu 100 km.



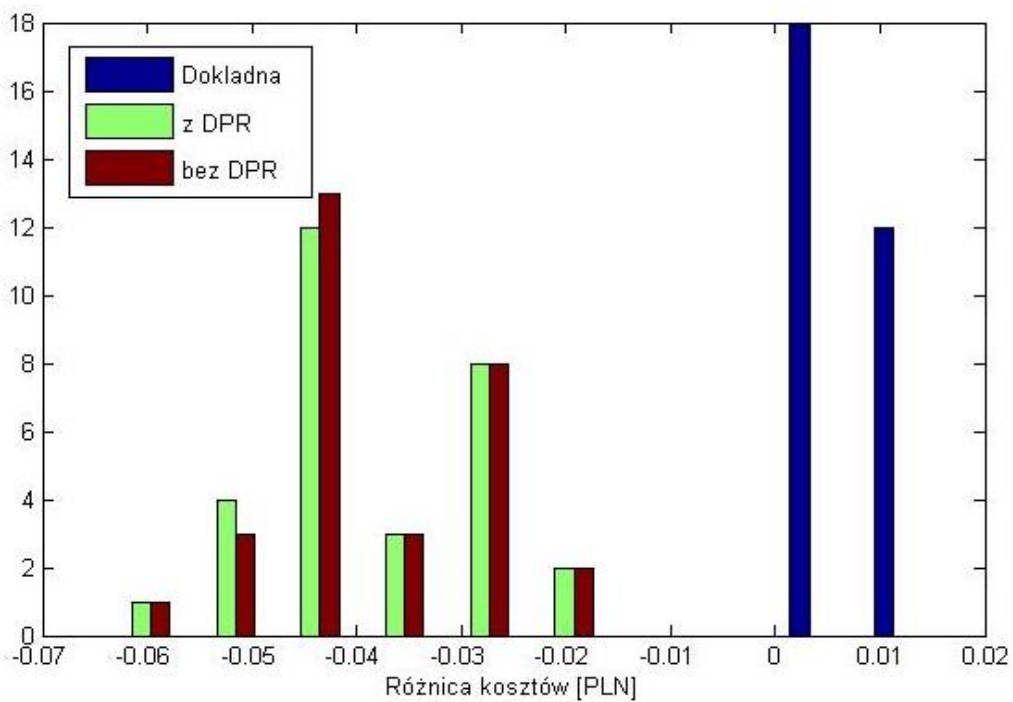
Rys. 25 Histogram różnicy kosztów pokonania trasy względem strategii „Dokładnej”

Pierwszym wnioskiem, jaki można wysnuć z porównania kosztów pokonania trasy dla strategii „Dokładnej” względem innych strategii, jest fakt, że dla wszystkich profili prędkości, niezależnie od zastosowanej strategii, w przypadku strategii „Dokładnej” uzyskano najlepszy wynik. Pokazuje to potencjał proponowanej w rozprawie metody, przy dokładnej realizacji predykcji prędkości. Korzyści z pokonania trasy z użyciem strategii „Dokładnej”, nie przekraczają w żadnym przypadku 1% ogólnych kosztów, najczęściej kształtując się w okolicy 0,5%, ogólnych kosztów pokonania trasy.

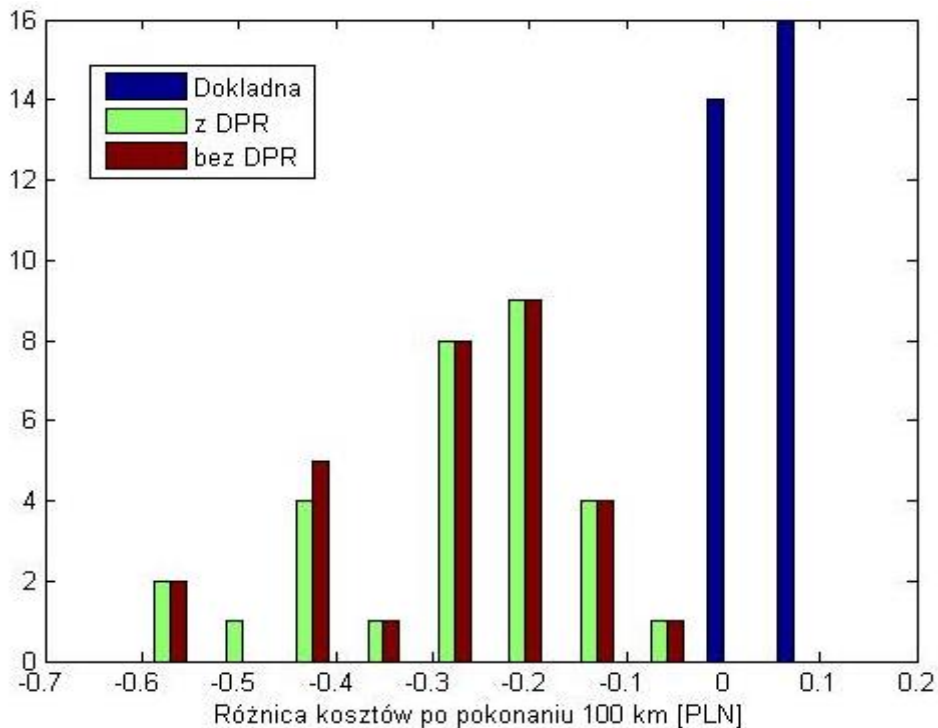
Kolejne porównanie kosztów dotyczyło kosztów dla strategii z użyciem prostych reguł - „Reguły”. Podobnie jak poprzednio, wyniki porównano odejmując koszty poniesione z użyciem strategii „Reguły” od kosztów poniesionych z wykorzystaniem innych reguł. Wyniki przedstawiono w formie histogramu na rys. 27, a także na rys. 28 - w przeliczeniu na 100 km.



Rys. 26 Histogram różnicy kosztów pokonania trasy względem strategii „Dokładnej” na 100 km



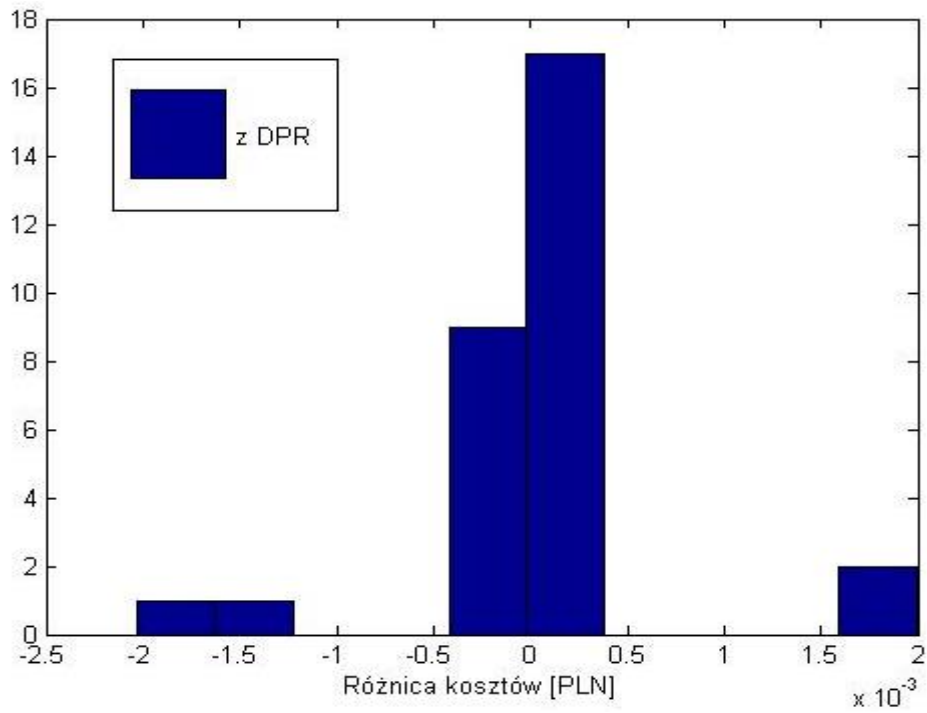
Rys 27 Histogram różnicy kosztów pokonania trasy względem strategii „Reguły”



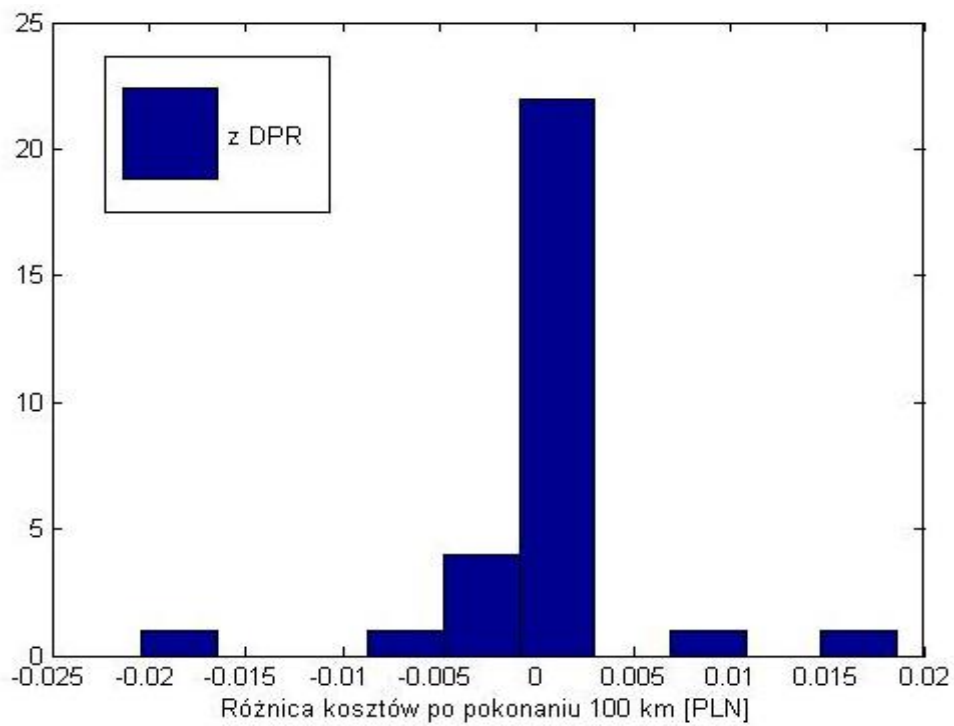
Rys 28 Histogram różnicy kosztów pokonania trasy względem strategii „Reguły” na 100 km

Po analizie danych należy stwierdzić, że w każdym z przypadków koszty pokonania trasy z użyciem reguł, okazały się mniejsze niż w przypadku zaproponowanej metody. Oznacza to, że proponowana metoda nie spełnia pokładanych w niej nadziei i jej stosowanie nie jest uzasadnione ekonomicznie. Należy przy tym pamiętać, że wyniki proponowanej metody nie różnią się znacząco od wyników uzyskanych przez tradycyjnie stosowaną strategię z wykorzystaniem reguł. Nawet w skrajnie niekorzystnym przypadku wyniki nie różnią się o więcej niż 0,7%, całkowitych kosztów przejazdu. Jednocześnie, należy jednak pamiętać o 2 profilach prędkości, których pokonanie okazało się niemożliwe z wykorzystaniem strategii opartej na regułach. Analiza wyników uzyskanych z symulacji metody „Dokładna”, wskazuje zaś na potencjał metody w przypadku dokładnej predykcji prędkości.

Ostatnia analiza dotyczyła różnicy kosztów pomiędzy algorytmem *MPC* ze stałym współczynnikiem i z wykorzystaniem *DPR*. Przedstawiają ją rys. 29 i 30. Analizując wyniki tego porównania należy zauważyć, że w większości przypadków proponowana metoda okazała się korzystna w stosunku do metody z wykorzystaniem stałej wartości współczynnika dla algorytmu *MPC*. Dotyczyło to 19 na 30 przebadanych profili prędkości. Średnia różnica także wskazuje na przewagę metody wykorzystującej zmienny współczynnik *MPC* wynosząc $2,9422 \cdot 10^{-5}$ PLN i $1,9583 \cdot 10^{-4}$. Jednocześnie jednak uzyskane koszty są bardzo zbliżone pomiędzy obiema metodami i różnica pozbawiona jest znaczenia ekonomicznego. Należy zauważyć, że zastosowanie zmiennych współczynników niemal w ogóle nie zwiększyło wymaganych nakładów obliczeniowych, zwiększając praktycznie niezauważalnie czas trwania obliczeń. Przemawia to na korzyść proponowanej metody.



Rys 29 Histogram różnicy kosztów pomiędzy proponowaną strategią a strategią ze stałym parametrem *MPC*



Rys 30 Histogram różnicy kosztów pomiędzy proponowaną strategią a strategią ze stałym parametrem *MPC* na 100 km

7 Podsumowanie

Przedstawiona praca jest wynikiem badań autora nad metodami zarządzania energią w pojeździe *PHEV*. Celem przedstawionej rozprawy doktorskiej było opracowanie metody zarządzania energią w pojeździe *PHEV*, z zamiarem zmniejszenia całkowitej energochłonności pojazdu. Samo zmniejszenie energochłonności pojazdu może odbywać się zarówno poprzez zmiany konstrukcyjne w budowie pojazdu jak i poprzez właściwe gospodarowanie energią w pojeździe podczas jego eksploatacji. Autor niniejszej rozprawy zdecydował się na skupić wyłącznie na części związanej z eksploatacją pojazdu i optymalnym gospodarowaniem energią w pojeździe. W pierwszym etapie pracy autor szczegółowo przeanalizował istniejące metody, algorytmy i strategie wykorzystywane do zarządzania energią w pojazdach o napędzie hybrydowym. Następnie autor zaproponował nową metodę będącą syntezą innych istniejących metod. Autor szczególnie nacisk położył na możliwości zastosowania metody online. W celu weryfikacji tezy rozprawy oraz przedstawionej metody konieczne okazało się utworzenie modelu symulacyjnego pojazdu, który opracowano z wykorzystaniem oprogramowania Matlab. Aby umożliwić dostrojenie parametrów nowo proponowanej metody oraz weryfikację numeryczną tezy rozprawy, a także zaproponowanej metody, konieczne było utworzenie sztucznych profili prędkości pojazdu o zadanych parametrach. W tym celu opracowano metodę służącą do generowania losowych profili prędkości o zadanych parametrach. Po dostrojeniu parametrów proponowanej metody, przystąpiono do jej weryfikacji numerycznej z wykorzystaniem sztucznie utworzonych profili prędkości. Po weryfikacji metody, jej wynik okazał się porównywalny do referencyjnej metody z wykorzystaniem reguł. Należy przy tym zaznaczyć, że metoda referencyjna okazała się bardziej efektywna. Pomimo tego, teza pracy została wykazana, ponieważ osiągnięto wyraźnie różne wyniki dla różnych metod zarządzania energią w pojeździe, przy badaniu identycznych profili prędkości. Zależność ta występowała we wszystkich badanych profilach prędkości pojazdu, choć wielkość różnicy jest uzależniona od samego profilu prędkości. Wykazano ponadto, że istnieje możliwość poprawy w stosunku do najczęściej stosowanych strategii z wykorzystaniem reguł, poprzez zmianę sposobu zarządzania energią w pojeździe.

7.1 Wnioski

Przedstawione w rozprawie wyniki badań potwierdzają słuszność przyjętej w pracy tezy. Potwierdzono, że istnieje możliwość zmniejszenia energochłonności pojazdu poprzez zastosowanie odpowiedniej metody zarządzania energią w pojeździe. Na podstawie pracy można wysunąć następujące wnioski:

- **Istnieje możliwość opracowania metod zarządzania energią w pojeździe *HEV*, które mogłyby pracować online, zapewniając możliwość optymalnego zarządzania energią w**

trakcie eksploatacji pojazdu, zmniejszając jego całkowitą energochłonność, co podlegało badaniu w tezie rozprawy.

- **Metoda zarządzania energią w przypadku pojazdu typu *HEV* ma istotne znaczenie dla całkowitej energochłonności pojazdu oraz kosztów jego eksploatacji.**
- W pracy opracowano metodę tworzenia sztucznych profili prędkości o zadanych parametrach. Metoda pozwala na utworzenie profili zbliżonych do rzeczywistych profili, zarejestrowanych w trakcie eksploatacji pojazdu. Prezentowana metoda może być skutecznie stosowana do tworzenia testowych profili prędkości na potrzeby symulacji numerycznych zużycia energii w pojazdach.

Dodatkowo można wysunąć bardziej szczegółowe wnioski dotyczące zaprezentowanej metody:

- Zaproponowana metoda okazała się porównywalna ze strategią opartą na regułach. Strategia oparta na regułach okazała się bardziej efektywna, przy czym perspektywicznie możliwe jest uzyskanie lepszego wyniku po modyfikacji proponowanej metody. W przypadku lepszej predykcji prędkości pojazdu możliwa jest znacząca poprawa wyniku. Na obecnym etapie stosowanie przedstawionej metody nie jest uzasadnione ekonomicznie.
- Prezentowana metoda, pomimo że była skomplikowaną i hierarchiczną metodą, wykorzystującą prace kilku algorytmów, okazała się możliwa do zastosowania online. Wprawdzie czas obliczeń dla proponowanej metody okazał się zbliżony do czasu trwania symulacji, jednak możliwe jest znaczące zmniejszenie czasu obliczeń poprzez optymalizację kodu programu, która nie została przeprowadzona w niniejszej rozprawie.
- Zastosowanie algorytmu rozpoznawania wzorców jazdy i zmiennego parametru sterującego dla *MPC* poprawiło w większości przypadków dokładność algorytmu *MPC* z wykorzystaniem strategii zmiennej eksponentjalnie w stosunku do stałego parametru sterującego. Poprawa ta nie zachodziła jednak w każdym przypadku, zaś różnice okazały się minimalne.
- Zaprezentowana metoda nie nadaje się do zastosowania w przypadku pojazdów prowadzonych przez kierowcę. W przypadku pojazdów autonomicznych, w których pewność co do zmiany prędkości pojazdu jest znacząca wyższa, przedstawiona metoda jest możliwa do zastosowania, przyczyniając się do zmniejszenia energochłonności pojazdu i kosztów jego eksploatacji.

7.2 Kierunki dalszych prac

Choć prezentowana metoda okazała się gorsza od tradycyjnie stosowanych strategii sterowania z wykorzystaniem reguł, to jednak możliwe jest jej ulepszenie poprzez wymianę elementów składowych metody. W metodzie wykorzystano algorytm *DPR* jako kontekst do wyboru odpowiedniego parametru sterującego *MPC*. Choć wykorzystanie *DPR* nie wykazało w sposób bezsporny poprawy wyników, to wydaje się, że zastosowanie algorytmu było dobrym pomysłem. Dodatkowo można zastosować

dodatkowe konteksty takie jak wykorzystanie systemów *ITS*. Istnieje także możliwość zmiany samego algorytmu. Algorytm *MPC* okazał się najsłabszym ogniwem zaprezentowanej metody. Choć sam algorytm jest niezbędny, by móc dostarczyć dane do kolejnego algorytmu, którym jest optymalizacyjny algorytm programowania dynamicznego, to wybór konkretnego spośród istniejących algorytmów *MPC*, okazał się być błędny. Autor niniejszej rozprawy kierował się chęcią opracowania metody możliwej do zastosowania online, z tego powodu wybór padł na metodę o niskiej złożoności obliczeniowej. Okazała się ona jednak zdecydowanie zbyt mało dokładna. W przyszłości możliwe jest zastosowanie bardziej złożonych algorytmów *MPC*, które potrafią dokładniej przewidywać prędkość pojazdu. Zmiana algorytmu jest niezbędnym krokiem na drodze rozwoju prezentowanej metody. Wreszcie, istnieje możliwość optymalizacji kodu programu w celu zmniejszenia czasu obliczeń i zwiększenia długości predykcji i optymalizacji, bądź jej dokładności. Powinno to umożliwić uzyskanie dokładniejszych wyników, a tym samym poprawę rezultatów. Samo zastosowanie programowania dynamicznego *DP* okazało się być bardzo dobrym pomysłem. Aby jednak było możliwe jego zastosowanie konieczna jest dokładna predykcja prędkości pojazdu, która jest kluczowa do dalszego rozwoju metody. Istnieje także możliwość dalszego rozwoju innych metod i algorytmów oraz tworzenie nowych metod wykorzystujących już istniejące rozwiązania. Pozwoli to na przyszłe zmniejszenie energochłonności pojazdów *HEV* oraz ograniczenie kosztów ich eksploatacji.

Bibliografia

- 1 M. Ehsani, Y. Gao, S. E. Gay, A. Emadi. *Modern Electric, Hybrid Electric, and Fuel Cell Vehicles. Fundamentals, Theory, and Design, Second Edition*. CRC Press, 2005.
- 2 C.C. Chan and K.T. Chau, *Modern Electric Vehicle Technology*, Oxford University Press, 2001
- 3 A. Chmielewski, K. Lubikowski, S. Radkowski, *Energy Storage Technologies: Review*, Proceedings Of The Institute Of Vehicles, 102: 13- 21, 2015
- 4 Z. Chłopek. *Ocena drogowego zużycia energii przez samochód elektryczny*. Transport Samochodowy, 1, 97: 33-39, 2004
- 5 A. Chmielewski, K. Lubikowski, R. Gumiński, S. Radkowski, P. Szulim, *Modeling Of The Properties Of Automotive Batteries Of An Electrical Vehicle Operating in NEDC Cycle*, Proceedings Of The Institute Of Vehicles, 95: 21- 30, 2013
- 6 S. Fui Tie, Ch. Wei Tan, *A review of Energy sources and Energy management system in electric vehicles* Renewable and Sustainable Energy Reviews, 20: 82- 102, 2013
- 7 P. Zhang, F. Yan, Ch. Du, *A comprehensive analysis of Energy management strategies for hybrid electric vehicles based on bibliometrics*, Renewable and Sustainable Energy Reviews, 48: 88- 104, 2015
- 8 Y. Huang, H. Wang, A. Khajepour, H. He, J. Ji, *Model predictive control power management strategies for HEVs: A review*, Journal of Power Sources, 341: 91- 106, 2017
- 9 Oficjalna strona zespołu Smart Power, dostęp 13.04.2019- <https://smartpower.polsl.pl/>
- 10 Oficjalna strona zawodów Shell Eco- Marathon (edycja Europejska), dostęp 13.04.2019 - <https://www.shell.com/make-the-future/shell-ecomarathon/europe.html>
- 11 S. Zhang, R. Xiong, F. Sun, *Model predictive control for power management in a plug-in hybrid electric vehicle with a hybrid energy storage system*, Applied Energy, 185: 1654- 1662, 2017
- 12 L. Li, S. You, Ch. Yang, B. Yan, J. Song, Z. Chen, *Driving-behavior-aware stochastic model predictive control for plug-in hybrid electric buses*, Applied Energy, 162: 868- 879, 2016
- 13 S. Xie, H. He, J. Peng, *An energy management strategy based on stochastic model predictive control for plug-in hybrid electric buses*, Applied Energy, 196: 279- 288, 2017
- 14 D. Lanzarotto, M. Marchesoni, M. Passalacqua, A. Pini Prato, M. Repetto, *Overview of different hybrid vehicle architectures* IFAC-PapersOnLine, 9, 51: 218-222, 2018
- 15 S. Borthakur, S. C. Subramanian, *Optimized Design and Analysis of a Series-Parallel Hybrid Electric Vehicle Powertrain for a Heavy Duty Truck* IFAC-PapersOnLine, 1/51:184-189, 2018.
- 16 A. M. Andwaria, A. Pesiridisa, S. Rajooc, R. M.- Botasd, V. Esfahanian, *A review of Battery Electric Vehicle technology and readiness levels*, Renewable and Sustainable Energy Reviews, 78: 414- 430, 2017
- 17 S. Manzetti, F. Mariasiu, *Electric vehicle battery technologies: From present state to future systems*, Renewable and Sustainable Energy Reviews, 51: 1004- 1012, 2015
- 18 M. Andre', *The ARTEMIS European driving cycles for measuring car pollutant emissions*, Science of the Total Environment, 334- 335: 73- 84, 2004
- 19 L. Ming, Y. Yinga, L. Lianga, L. Yaoa, W. Zhoua, *Energy management strategy of a plug-in parallel hybrid electric vehicle using fuzzy control* Energy Procedia, 105: 2660- 2665, 2017
- 20 D. Meng, Y. Zhang, M. Zhou, R. Na *Intelligent fuzzy energy management research for a uniaxial parallel hybrid electric vehicle* Computers and Electrical Engineering, 58: 447- 464, 2017
- 21 Y. Zhang , L. Chu, Z. Fu, N. Xu, Ch. Guo, X. Zhang, Z. Chen, P. Wang, *Optimal energy management strategy for parallel plug-in hybrid electric vehicle based on driving behavior analysis and real time traffic information prediction*, Mechatronics, 46: 177–192, 2017
- 22 Y. Wang, X. Wang, Y. Sun, S. You, *Model predictive control strategy for energy optimization of series-parallel hybrid electric vehicle*, Journal of Cleaner Production, 199: 348- 358, 2018
- 23 J. Peng, H. He, R. Xiong, *Rule based energy management strategy for a series–parallel plug-in hybrid electric bus optimized by dynamic programming*, Applied Energy, 185: 1633- 1643, 2017

- 24 Z. Chen, B. Xia, Ch. You, Chunting Ch. Mi, *A novel energy management method for series plug-in hybrid electric vehicles*, Applied Energy, 145: 172- 179, 2015
- 25 L. Li, B. Yan, J. Song, Y. Zhang, G. Jiang , L. Li, *Two-step optimal energy management strategy for single-shaft series-parallel powertrain*, Mechatronics, 36: 147–158, 2016
- 26 J. Park, J.-H. Park, *Development of equivalent fuel consumption minimization strategy for hybrid electric vehicles*, International Journal of Automotive Technology, 13, 5: 835–843, 2012
- 27 T. van Keulen, B. de Jager, A. Serrarens, M. Steinbuch, *Optimal Energy Management in Hybrid Electric Trucks Using Route Information*, Oil & Gas Science and Technology, 65, 1: 103- 113, 2010
- 28 F. R. Salmasi, *Control Strategies for Hybrid Electric Vehicles: Evolution, Classification, Comparison, and Future Trends*, IEEE Transactions On Vehicular Technology, 56, 5: 2393- 2404, 2007
- 29 C. Guardiola, B. Pla, S. Onori, G. Rizzoni, *Insight into th eHEV/PHEV optimal control solution based on a new tuning method*, Control Engineering Practice, 29: 247- 256, 2014
- 30 M. Kim, D. Jung, K. Min, *Hybrid Thermostat Strategy for Enhancing Fuel Economy of Series Hybrid Intracity Bus*, IEEE Transactions On Vehicular Technology, 63, 8: 3569- 3579, 2014
- 31 K.T. Chau , Y.S. Wong, *Overview of power management in hybrid electric vehicles*, Energy Conversion and Management, 43: 1953–1968, 2002
- 32 J. Park, J. Oh, Y. Park, K. Lee *Optimal Power Distribution Strategy for Series- Parallel Hybrid Electric Vehicles*, 2006 International Forum on Strategic Technology, 18-20. 10. 2006, Chittagong, Bangladesh, 37- 42
- 33 B. Baumann, G. Rizzoni, G. Washington, *Intelligent Control Of The Ohio State University Hybrid-Electric Vehicle*, IFAC Proceedings Volumes, 31, 1: 119- 124, 1998
- 34 L. Hyeoun-Dong, S. Seung-Ki, *Fuzzy-Logic-Based Torque Control Strategy for Parallel-Type Hybrid Electric Vehicle*, IEEE Transactions On Industrial Electronics, 45, 4: 625- 632, 1998
- 35 S. G. Li, S. M. Sharkh, F. C. Walsh, and C. N. Zhang, *Energy and Battery Management of a Plug-In Series Hybrid Electric Vehicle Using Fuzzy Logic*, IEEE Transactions On Vehicular Technology, 60, 8: 3571- 3585, 2011
- 36 W. Xiong , Y. Zhang, Ch. Yin, *Optimal energy management for a series–parallel hybrid electric bus*, Energy Conversion and Management 50: 1730–1738, 2009
- 37 M. Kurzyński, *Metody Sztucznej inteligencji dla inżynierów*, Stowarzyszenie „Wspólnota Akademicka”, 2008
- 38 Z. Yi, Liu Heping, W. Huabin, *Torque Control Strategy for Parallel Hybrid Electric Vehicles using Fuzzy Logic*, WSEAS Transactions On Systems, 10, 6: 116- 125, 2011
- 39 J.- S. Won, R. Langeri, *Fuzzy torque distribution control for a paralel hybrid vehicle*, Experts Systems, 19, 1: 4-10, 2002
- 40 M. Farrokhi, M. Mohebbi, *Optimal Fuzzy Control of Parallel Hybrid Electric Vehicles*, ICCAS 2-5. 06. 2005: 1-5
- 41 Y. L. Murphey, J. Park, Z. Chen, M. L. Kuang, M. A. Masrur, A. M. Phillips, *Intelligent Hybrid Vehicle Power Control—Part I: Machine Learning of Optimal Vehicle Power*, IEEE Transactions On Vehicular Technology, 61, 8: 3519- 3530, 2012
- 42 A. Poursamad, M. Montazeri, *Design of genetic-fuzzy control strategy for parallel hybrid electric vehicles*, Control Engineering Practice 16: 861–873, 2008
- 43 J. Wu, C.-H. Zhang, N.-X. Cui, *Fuzzy energy management strategy for a hybrid electric vehicle based on driving cycle recognition*, International Journal of Automotive Technology, 13, 7: 1159–1167, 2012
- 44 C. Y. Tseng, Y. H. Hung , C. H. Tsai, Y. J. Huang, *Parameters optimization for the energy management system of hybrid electric vehicle*, Proceedings of the SPIE, 6794: 1- 6, 2008
- 45 R. J. Zhang, Y. B. Chen. *Control of hybrid dynamical systems for electric vehicles*, Proceedings of the American control conference: 2884–2889, 2001

- 46 M. Montazeri, A. Poursamad, B. Ghalichi, *Application of genetic algorithm for optimization of control strategy in parallel hybrid electric vehicles*, Journal of the Franklin Institute 343: 420–435, 2006
- 47 Z. C. Wang, B. F. Huang, Y. S. Xu, W. M. Li. *Optimization of series hybrid electric vehicle operational parameters by simulated annealing algorithm*, Proceedings of the IEEE international conference on control and automation: 2124–2129, 2007
- 48 J. Wu, C.-H. Zhang, N.-X. Cui, *PSO algorithm-based parameter optimization for hev powertrain and its control strategy.*, International Journal of Automotive Technology, 9, 1: 53- 69, 2008
- 49 S. Delprat, T. M. Guerra, G. Paganelli, J. Lauber, M. Delhom. *Control strategy optimization for an hybrid paralel powertrain.*, Proceedings of the American control conference 2001: 1315–1320
- 50 N. Kim, A. Rousseau, *Sufficient conditions of optimal control based on Pontryagin's minimum principle for use in hybrid electric vehicles*, Journal o Automobile Engineering, 226, 9: 1160- 1170, 2012
- 51 S. Delprat, J. Lauber, T. M. Guerra, J. Rimaux, *Control of a Parallel Hybrid Powertrain: Optimal Control*, IEEE Transactions On Vehicular Technology, 53, 3: 872- 881, 2004
- 52 T. H. Pham, J. Kessels, P. P. J. van den Bosch, R. G. M. Huisman, R. Nevels, *On-line energy and battery thermal management for hybrid electric heavy-duty truck*, Proceedings of the American control conference 2013: 710–715
- 53 J. T. B. A. Kessels, M. W. T. Koot, P. P. J. van den Bosch, D. B. Kok, *Online Energy Management for Hybrid Electric Vehicles*, IEEE TRANSACTIONS ON VEHICULAR TECHNOLOGY, 57, 6,: 3428- 3440, 2008
- 54 H. Yu, M. Kuang, R. McGee, *Trip-oriented Energy management control for plug-in hybrid electric vehicles* .Proceedings of the fifth IEEE conference on decision and control European control conference 2011,: 5805–5812
- 55 D. Ambühl, O. Sundströma, A. Sciarretta, L. Guzzella, *Explicit optimal control policy and its practical application for hybrid electric powertrains*, Control Engineering Practice 18:1429–1439, 2010
- 56 N. Kim, S. W. Cha, H. Peng, *Optimal Equivalent Fuel Consumption for Hybrid Electric Vehicles*, IEEE Transactions On Control Systems Technology, 20, 3: 817- 825, 2012
- 57 J. Jeong, D. Lee, N. Kim, Y. Park, S. W. Cha *Fuel economy analysis of a paralel hybrid bus using the optimal control theory*. Proceedings of the IEEE vehicle power and propulsion conference 2011, 1–5
- 58 N. W. Kim, D. H. Lee, C. Zheng, C. Shin, H. Seo, S. W. Cha, *Realization of pmp-based control for hybrid electric vehicles in a backward-looking simulation*, International Journal of Automotive Technology, 15, 4: 625– 635, 2014
- 59 C. Hou, M. Ouyang, L. Xu, H. Wang, *Approximate Pontryagin's minimum principle applied to the Energy management of plug-in hybrid electric vehicles*, Applied Energy 115: 174–189, 2014
- 60 L. V. Perez, G. O. Garcia, *State constrained optimal control applied to supervisory control in HEVs. Oil Gas Sci Technol – Revued IFP Energies Nouv*, 65:191–201, 2010
- 61 R. Dosthosseini, A. Z. Kouzani, F. Sheikholeslam, *Direct method for optimal power management in hybrid electric vehicles*, International Journal of Automotive Technology, 12, 6: 943–950, 2011
- 62 I.V. Kolmanovskya, L. Lezhnevb, T.L. Maizenbergc, *Discrete-time drift counteraction stochastic optimal control: Theory and application-motivated examples*, Automatica 44: 177 – 184, 2008
- 63 B. Sampathnarayananana, S. Onori, S. Yurkovich, *An optimal regulation strategy with disturbance rejection for Energy management of hybrid electric vehicles*, Automatica 50: 128–140, 2014
- 64 C. Dextreit, I. V. Kolmanovsky, *Game Theory Controller for Hybrid Electric Vehicles*, IEEE Transactions On Control Systems Technology, 22, 2: 652-663, 2014

- 65 O. Reyss, G. Duc, P. Pognant-Gros, G. Sandou, *Robust torque tracking control for E-IVT hybrid powertrain*, IFAC Proceedings Volumes, 41, 2, 2008: 6428- 6433
- 66 P. Pisu, E. Slani. G. Rizzoni, S. M. Savaresi, *A LMI-based Supervisory Robust Control for Hybrid Vehicles*, Proceedings of the 2003 American Control Conference, 2003,: 4681- 4686
- 67 P. Pisu G. Rizzoni, *Control for Hybrid Electric Vehicles*, 43rd IEEE Conference on Decision and Control Atlantis, 14-17, 12. 2004, Paradise Island, Bahamas: 3497- 3502
- 68 E. Dincmen, I. M. C. Uygan, A. B. Guvenc, T. Acarman. *Powertrain control of paralel hybrid electric vehicles via extremum seeking algorithm*, Proceedings of the ASME tenth biennial conference on engineering systems design and analysis:147–156, 2010
- 69 Y. Wang, Z. X. Sun, *SDP-based extremum seeking Energy management strategy for a power split hybrid electric vehicle*, Proceedings of the American control conference 2012: 553–558, 2012
- 70 R. Liu, D. Shi, Ch. Ma, *Real-Time Control Strategy of Elman Neural Network for the Parallel Hybrid Electric Vehicle*, Journal of Applied Mathematics 2014: 1- 11, 2014
- 71 Z. C Wang, W. M. Li, Y.S. Xu. *A novel power control strategy of series hybrid electric vehicle*, Proceedings of international conference on intelligent robots and systems; 96–102, 2007
- 72 H. H. Chin, A. A. Jafari. *A selection algorithm for power controller unit of hybrid vehicles* Proceedings of the fourteenth international IEEE conference, Intelligent transportation systems: 324– 328, 2011
- 73 G. Paganelli, T. M. Guerra, S. Delprt, J. J. Santin, M. Delhom, E. Combes, *Simulation and assessment of power control strategies for a paralel hybrid car*, ProcInst Mech EngPartD – J Automob Eng, 214: 705–717, 2000
- 74 G. Paganelli, S. Delprat, T. M. Guerra, J. Rimaux, J. J. Santin, *Equivalent consumption minimization strategy for paralel hybrid powertrains*, Proceedings of the fifty- fifth IEEE vehicular technology conference: 2076–2081, 2002
- 75 F. Vidal-Naquet, G. Zito, *Adapted optimal Energy management strategy for drivability*, Proceedings of the IEEE vehicle powerand propulsion conference: 358–363, 2012
- 76 D. Sinoquet, G. Rousseau, Y. Milhau, *Design optimization and optimal control for hybrid vehicles*, Optim Eng, 12: 199–213, 2011
- 77 L. Li, H. Huang, J. Lian, B. Yao, Y. Zhou, J. Chang, N. Zheng, *Research of Ant Colony Optimized Adaptive Control Strategy for Hybrid Electric Vehicle*, Mathematical Problems in Engineering Volume 2014: 1- 10, 2014
- 78 X. Ye, Z. Jin, X. Hu, Y. Li, Q. Lu, *Modeling and control strategy development of a parallel hybrid electric bus*, International Journal of Automotive Technology, 14, 6: 971–985, 2013
- 79 D. Pei, M. J. Leamy, *Dynamic Programming-Informed Equivalent Cost Minimization Control Strategies for Hybrid-Electric Vehicles*, Journal of Dynamic Systems, Measurement, and Control, 135: 1- 17, 2013
- 80 M. Khodabakhshian, L. Feng, J. Wikander. *Improving fuel economy and robustness of animproved ECMS method*, Proceedings of the tenth IEEE international conference on control and automation: 598- 603, 2013
- 81 A. Sciarretta, M. Back, L. Guzzella, *Optimal Control of Parallel Hybrid Electric Vehicles*, IEEE Transactions On Control Systems Technology, 12, 3: 352- 363 2004
- 82 B. Geng, J. K. Mills, D. Sun, *Energy Management Control of Microturbine-Powered Plug In Hybrid Electric Vehicles Using the Telemetry Equivalent Consumption Minimization Strategy*, IEEE Transactions On Vehicular Technology, 60, 9: 4238- 4248, 2011
- 83 D. Ambühl, L. Guzzella, *Predictive Reference Signal Generator for Hybrid Electric Vehicles*, IEEE Transactions On Vehicular Technology, 58, 9: 4730- 4740, 2009
- 84 C Zhang, A Vahidi, *Route preview in energy management of plug-in hybrid vehicles*, IEEE Transactions on Control Systems Technology 20, 2: 546-553, 2012
- 85 C. Musardo, G. Rizzoni, Y. Guezennec, B. Staccia, *A-ECMS: An Adaptive Algorithm for Hybrid Electric Vehicle Energy Management*, European Journal of Control, 11: 509–524, 2005
- 86 J. Wang, Q.Wang, P. Wang, X. Zeng, *The Development and Verification of a Novel ECMS of Hybrid Electric Bus*, Mathematical Problems in Engineering 6: 1- 14, 2014

- 87 S. Di Cairano, D. Bernardini, A. Bemporad, I. V. Kolmanovsky, *Stochastic MPC With Learning for Driver-Predictive Vehicle Control and its Application to HEV Energy Management*, IEEE Transactions On Control Systems Technology, 22, 3: 1018- 1031, 2014
- 88 H. Wanga, Y. Huang, A. Khajepour, Q. Song, *Model predictive control-based energy management strategy for a series hybrid electric tracked vehicle*, Applied Energy 182: 105–114, 2016
- 89 S. Fekri, F. Assadian, *Fast Model Predictive Control and its Application to Energy Management of Hybrid Electric Vehicles*, Advanced Model Predictive Control, IntechOpen, 2011
- 90 A. Santucci, A. Sorniotti, C. Lekakou, *Power split strategies for hybrid energy storage systems for vehicular applications*, Journal of Power Sources 258: 395- 407, 2014
- 91 H. A. Borhan, A. Vahidi, A. M. Phillips, M. L. Kuang, I. V. Kolmanovsky, *Predictive Energy Management of a Power-Split Hybrid Electric Vehicle*, 2009 American Control Conference Hyatt Regency Riverfront, St. Louis, MO, USA 10-12, 06. 2009: 3970- 3976, 2009
- 92 Ch. Sun, X. Hu, S. J. Moura, F. Sun, *Velocity Predictors for Predictive Energy Management in Hybrid Electric Vehicles*, IEEE Transactions On Control Systems Technology, 23, 3: 1197- 1204, 2015
- 93 Q. Hu, W. Yue, *Markov Decision Processes with Their Applications*, Springer- Verlag New York, United States, 2007
- 94 L. Johannesson, M. Åsbogård, B. Egardt, *Assessing the Potential of Predictive Control for Hybrid Vehicle Powertrains Using Stochastic Dynamic Programming*, IEEE Transactions On Intelligent Transportation Systems, 8, 1: 71- 83, 2007
- 95 M. Josevski, D. Abel, *Energy Management of Parallel Hybrid Electric Vehicles based on Stochastic Model Predictive Control*, Proceedings of the 19th World Congress The International Federation of Automatic Control, 24- 29. 07. 2014, Cape Town, South Africa: 2132- 2137, 2014
- 96 S. J. Moura, H. K. Fathy, D. S. Callaway, J. L. Stein, *A Stochastic Optimal Control Approach for Power Management in Plug-In Hybrid Electric Vehicles*, IEEE Transactions On Control Systems Technology, 19, 3,: 545- 55, 2011
- 97 J. Wang, Y. Huang, H. Xie, G. Tian, *Driving Pattern Prediction Model for Hybrid Electric Buses Based on Real-World Driving Data*, EVS 28 International Electric Vehicle Symposium and Exhibition 1 EVS28 KINTEX, 3-6. 05. 2015. Korea:1 -8, 2015
- 98 J. Zhang, H. He, X. Wang, *Model Predictive Control Based Energy Management Strategy for a Plug-In Hybrid Electric Vehicle*, 3rd International Conference on Mechanical Engineering and Intelligent Systems (ICMEIS 2015): 875- 879, 2015
- 99 F. Payri, C. Guardiola, B. Pla, D. Blanco-Rodriguez, *A stochastic method for the Energy management in hybrid electric vehicles*, Control Engineering Practice, 29: 257– 265, 2014
- 100 A. Styler, I. Nourbakhsh, *Model Predictive Control with Uncertainty in Human Driven Systems*, Proceedings of the Twenty-Seventh AAAI Conference on Artificial Intelligence: 1348- 1354, 2013
- 101 Q. Gong, Y. Li, Z.-R Peng, *Trip-Based Optimal Power Management of Plug-in Hybrid Electric Vehicles*, IEEE Transactions On Vehicular Technology, 57, 6,:3393- 3401, 2008
- 102 L. Johannesson, S. Pettersson, B. Egardt, *Predictive Energy management of a 4QT series-parallel hybrid electric bus*, Control Engineering Practice 17: 1440–1453, 2009
- 103 Y. He, J. Rios, M. Chowdhury, P. Pisu, P. Bhavsar, *Forward power-train energy management modeling for assessing benefits of integrating predictive traffic data into plug-in-hybrid electric vehicles*, Transportation Research Part D 17: 201–207, 2012
- 104 Ch. Sun, F. Sun, X. Hu, J. K. Hedrick S. Moura, *Integrating Traffic Velocity Data into Predictive Energy Management of Plug-in Hybrid Electric Vehicles*, 2015 American Control Conference Palmer House Hilton 1-3. 07. 2015. Chicago, IL, USA,: 3267- 3272, 2015
- 105 M. A. M. Zulkefli, J. Zheng, Z. Sun, H. X. Liu, *Hybrid powertrain optimization with trajectory prediction based on inter-vehicle-communication and vehicle-infrastructure-integration*, Transportation Research Part C 45: 41–63, 2014
- 106 L. Fu, Ü. Özgüner, P. Tulpule, V. Marano, *Real-time Energy Management and Sensitivity Study for Hybrid Electric Vehicles*, 2011 American Control Conference on O'Farrell Street, San Francisco, CA, USA 29,06- 01. 07 2011: 2113- 2118, 2011

- 107 A. Fotouhi, R. Yusof, R. Rahmani, S. Mekhilef, N. Shateri, *A review on the applications of driving data and traffic information for vehicles' energy conservation*, Renewable and Sustainable Energy Reviews, 37: 822–833, 2014
- 108 I. Arsie, M. Graziosi, C. Pianese, G. Rizzo, M. Sorrentino, *Optimization of Supervisory Control Strategy for Parallel Hybrid Vehicle with Provisional Load Estimate*, Proc. of AVEC04, 483–488
- 109 F. Soriano, M. Moreno-Eguilaz, J. Álvarez-Flórez, *Drive Cycle Identification and Energy Demand Estimation for Refuse-Collecting Vehicles*, IEEE Transactions On Vehicular Technology, 64, 11: 4965–4973, 2015
- 110 Ch. Sun, F. Sun, H. He, *Investigating adaptive-ECMS with velocity forecast ability for hybrid electric vehicles*, Applied Energy 185: 1644–1653, 2017
- 111 T. Liu, Y. Zou, D. Liu, F. Sun, *Reinforcement Learning of Adaptive Energy Management With Transition Probability for a Hybrid Electric Tracked Vehicle*, IEEE Transactions On Industrial Electronics, 62, 12: 7937–7946, 2015
- 112 S. Kermani, S. Delprat, T. M. Guerra R. Trigui, B. Jeanneret, *Predictive Energy management for hybrid vehicle*, Control Engineering Practice 20: 408–420, 2012
- 113 R. Langari, J.-Seob Won, *Intelligent Energy Management Agent for a Parallel Hybrid Vehicle—Part I: System Architecture and Design of the Driving Situation Identification Process*, IEEE Transactions On Vehicular Technology, 54, 3: 925–934, 2005
- 114 A. Taghavipour Nasser L. Azad, John McPhee, *Real-time predictive control strategy for a plug-in hybrid electric powertrain*, Mechatronics 29, 13–27, 2009
- 115 A.G. Beccuti, G. Papafotiou, R. Frasca, M. Morari, *Explicit Hybrid Model Predictive Control of the dc–dc Boost Converter*, Proceedings of the 2011 14th European Conference on Power Electronics and Applications, EPE 2011: 2504–2509, 2011
- 116 Y. Wang, S. Boyd, *Fast Model Predictive Control Using Online Optimization*, Proceedings of the 17th World Congress The International Federation of Automatic Control, 6–11. 07. 2008, Seoul, Korea: 6974–6979, 2008
- 117 G. Ripaccioli, A. Bemporad, F. Assadian, C. Dextreit, S. Di Cairano, I.V. Kolmanovsky, *Hybrid modeling, identification, and predictive control: an application to hybrid electric vehicle energy management*, in: *Hybrid Systems: Computation and Control*, Springer Berlin Heidelberg, 2009
- 118 R. Scattolini, *Architectures for distributed and hierarchical Model Predictive Control – A review*, Journal of Process Control 19: 723–731, 2009
- 119 J. Unger, M. Kozek, S. Jakubek, *Non linear model predictive Energy management controller with load and cycle prediction for non-road HEV*, Control Engineering Practice 36,: 120–132, 2015
- 120 M. Joševski, D. Abel, *Multi-time Scale Model Predictive Control Framework for Energy Management of Hybrid Electric Vehicles*, 53rd IEEE Conference on Decision and Control 15–17. 12. 2014, Los Angeles, California, USA: 2523–2528, 2014
- 121 Z. Wei, Z. Xu, D. Halim, *Study of HEV power management control strategy Based on driving pattern recognition*, Energy Procedia 88: 847–853, 2016
- 122 S. Zhang, R. Xiong, *Adaptive energy management of a plug-in hybrid electric vehicle based on driving pattern recognition and dynamic programming*, Applied Energy 155: 68–78, 2015
- 123 H. –D. Lee, E. –S. Koo, S.-K. Sul, J.- S. Kim, M. Kamiya, H. Ikeda, S. Shinohara, H. Yoshida, *Torque control strategy for a parallel-hybrid vehicle using fuzzy logic*, IEEE Industry Applications Magazine, 6, 6: 33–38, 2000
- 124 Zhenzhen Lei, Datong Qin, Yonggang Liu, Zhiyuan Peng, Lilai Lu, *Dynamic energy management for a novel hybrid electric system based on driving pattern recognition*, Applied Mathematical Modelling 45: 940–954, 2017
- 125 R. Langari, J.-S. Won, *Intelligent Energy Management Agent for a Parallel Hybrid Vehicle—Part I: System Architecture and Design of the Driving Situation Identification Process*, IEEE Transactions On Vehicular Technology, 54, 3: 925–934, 2005
- 126 T. R. Carlson R. C. Austin, *Development of speed correction cycles*, Sierra Research, Inc., Sacramento, CA, Report SR97-04-01, 1997
- 127 V. Di Lecce, M. Calabrese, *NN-based measurements for driving pattern classification*, I2MTC 2009 - International Instrumentation and Measurement Technology Conference, 5–7 May 2009, Singapore, 1–6, 2009
- 128 X. Zhang, G. Wu, Z. Dongn, C. Crawford, *Embedded feature-selection suport vector machine for driving pattern recognition*, Journal of then Franklin Institute 352: 669–685, 2015

- 129 Z. Liang, Z. Xin, T. Yi, Z. Xinn, *Intelligent Energy Management Based on the Driving Cycle Sensitivity Identification Using SVM*, 2009 Second International Symposium on Computational Intelligence and Design, 12-14. 12. 2009, Changsha, China: 513- 516, 2009
- 130 R. E. Bellman, S. E. Dreyfus, *Programowanie dynamiczne (Zastosowanie)*, Państwowe wydawnictwo ekonomiczne, Warszawa 1967
- 131 S. E. Lyshevski, C. Yokomoto, *Control of hybrid- electric vehicles*, Proceedings of the American control conference;1998: 2148–2149, 1998
- 132 Ch.-Ch. Lin, H. Peng, J. W. Grizzle, J.-M. Kang, *Power Management Strategy for a Parallel Hybrid Electric Truck*, IEEE Transactions On Control Systems Technology, 11, 6: 839- 849, 2003
- 133 G.-Q. Ao, J.-X. Qiang, H. Zhong, L. Yang, B. Zhuo, *Exploring The Fuel Economy Potential Of Isg Hybrid Electric Vehicles Through Dynamic Programming*, International Journal of Automotive Technology, 8, 6, 781–790, 2007
- 134 F. Sun, R. Xiong, H. He, *A systematic state-of-charge estimation framework for multi-cell battery pack in electric vehicles using bias correction technique*, Applied Energy 162,: 1399–1409, 2016
- 135 P. Czop, *Application Of An Inverse Data-Driven Model For Reconstructing Wheel Movement Signals*, Metrology and Measurement Systems, 3: 491- 500, 2011
- 136 S. Zhang, R. Xiong, X. Zhou, *Comparison of the topologies for a hybrid energy-storage system of electric vehicles via a novel optimization method*, Science China Technological Sciences, 58, 7: 1173–1185, 2015
- 137 Q. Liua, J. Fua, G. Zhua, Q. Lia, J. Liua, X. Duana, Q. Guoc, *Comparative study on thermodynamics, combustion and emissions of turbocharged gasoline direct injection (GDI) engine under NEDC and steadystate conditions*, Energy Conversion and Management, 169: 111–123, 2018
- 138 V. Schwarzer, R. Ghorbani, *Drive Cycle Generation for Design Optimization of Electric Vehicles*, IEEE Transactions On Vehicular Technology, 62, 1: 89- 97, 2013
- 139 J. Pavlovica, B. Ciuffoa, G. Fontarasa, V. Valverdea, A. Marottab, *How much difference in type-approval CO2 emissions from passenger cars in Europe can be expected from changing to the new test procedure (NEDC vs. WLTP)?*, Transportation Research Part A 111,: 136–147, (2018)
- 140 T. Austin, F. DiGenova, T. Carlson, R. Joy, K. Gianolini, and J. Lee, *Characterization of Driving Patterns and Emissions From Light-Duty Vehicles in California*, Sierra Res., Inc., Sacramento, CA, Tech. Rep., 1993
- 141 J. Lin, D. A. Niemeier, *Estimating Regional Air Quality Vehicle Emission Inventories: Constructing Robust Driving Cycles*, Transportation Science, 37, 3: 330- 346, 2003
- 142 G. Souffran, L. Miègeville, P. Guérin, *Simulation of Real-World Vehicle Missions Using a Stochastic Markov Model for Optimal Design Purposes*, Proc. IEEE Vehicle Power and Propulsion Conference, 2011: 1–6, 2011
- 143 E. Tazelaar, J. Bruinsma, B. Veenhuizen, P. van den Bosch, *Driving cycle characterization and generation, for design and control of fuel cell buses*, World Electric Vehicle Journal, 3,: 812- 819, 2009
- 144 A. Ravey, N. Watrin, B. Blunier A. Miraoui, *Energy Sources Sizing for Hybrid Fuel Cell Vehicles Based on Statistical Description of Driving Cycles*, IEEE Trans. Veh. Technol., 60, 9,: 4164–4174, 2011.

Metoda optymalizacji energochłonności pojazdu z napędem hybrydowym z wykorzystaniem zarządzania energią w pojeździe

Praca doktorska - streszczenie

Autor: mgr inż. Mateusz Tyczka

Promotor: Dr hab. inż. Wojciech Skarka prof. nzw. w Pol. Śl.
Politechnika Śląska, Wydział Mechaniczny Technologiczny

Celem niniejszej pracy doktorskiej było opracowanie metody zarządzania energią w pojazdach *PHEV* z zamiarem zmniejszenia ich energochłonności oraz kosztów ich eksploatacji. Pierwszym etapem realizacji rozprawy było pozyskanie wiedzy na temat zarządzania energią w pojazdach o napędzie hybrydowym. Zaproponowana metoda stanowiła połączenie trzech innych znanych algorytmów i miała charakter hierarchiczny. Dane wyjściowe pierwszej metody stanowiły wejście dla kolejnego algorytmu. Proponowana metoda została szczegółowo opisana wraz z uzasadnieniem wyboru konkretnych algorytmów wchodzących w jej skład. Badania nad metodą prowadzone były numerycznie, z wykorzystaniem modelu utworzonego przy użyciu oprogramowania Matlab. W celu dostrojenia parametrów metody, autor opracował metodę tworzenia sztucznych profili prędkości. Metoda generowania profili prędkości pozwalała na tworzenie profili o konkretnej charakterystyce, odpowiadającej różnym sytuacjom drogowym, takim jak przejazd po autostradzie czy poruszanie się w zatłoczonym mieście. Dzięki temu możliwe było uwzględnienie różnych warunków jazdy, zarówno podczas strojenia parametrów jak i weryfikacji samej metody proponowanej w niniejszej pracy. Weryfikacja została przeprowadzona dla losowych profili prędkości. Polegała ona na porównaniu wyników proponowanej metody z wynikami prostej strategii opartej o reguły. Dodatkowo przeprowadzono symulacje dla modyfikacji proponowanej metody by wyciągnąć bardziej szczegółowe wnioski. Pomimo że proponowana metoda nie spełniła pokładanej w niej nadziei na zmniejszenie energochłonności pojazdu względem prostej strategii opartej na regułach, teza pracy została udowodniona, gdyż wyniki zmodyfikowanych metod pokazują, że możliwe jest zmniejszenie energochłonności przy zastosowaniu dokładniejszych algorytmów. Wyniki pracy zostały szczegółowo przedyskutowane, wyciągnięto wnioski oraz zaproponowano dalsze kierunki prac.

Słowa kluczowe: samochód hybrydowy, optymalizacja zużycia energii, pojazd elektryczny

Energy consumption optimization method for a hybrid electric vehicle using the vehicle's energy management

PhD dissertation - Summary

Author: Mateusz Tyczka MSc, Eng.

Supervisor: Prof. Wojciech Skarka, PhD, DSc Eng.

Silesian University of Technology, Faculty of Mechanical Engineering

The aim of this PhD thesis was to gain knowledge about energy management in Hybrid Electric Vehicles, in order to reduce their energy consumption and the cost of their exploitation. The aim has been realized by proposing a new energy management method in *HEV*. The proposed method is a hierarchic combination of three existing methods. The proposed method is hierarchical. The output of the main method has been used as the input for the next algorithm. The method has been described in details, and the choice of the component algorithms has been justified. The research has been conducted in a numeric way, using a model created in MATLAB software. In order to adjust the method's parameters, the author has created a method for creating artificial velocity profiles, which has helped to create profiles of particular and desired characteristics, so that they could reflect different situations on the road, such as driving on a highway or driving in a dense city traffic. This has allowed the author to include various driving conditions, both for the adjustment of the parameters and for the verification of the proposed method itself.

The verification has been based on random velocity profiles. It consisted of comparing the results obtained with the proposed method and the results obtained with a simple strategy based on rules. In addition, after the verification, additional simulations for modified method has been conducted, in order to draw more detailed conclusions. The proposed method did not meet the expectations regarding the reduction of energy consumption in *HEV* in comparison with the simple strategy based on rules. Nonetheless, the thesis of the dissertation has been proved, because the results obtained with the modified methods show that a reduction of energy consumption is possible, with the use of more detailed algorithms. The results have been discussed, conclusions have been drawn and future research directions have been suggested.

Keywords: hybrid electric vehicle, energy consumption optimization, electric vehicle