

Silesian University of Technology
Faculty of Mechanical Engineering
Department of Fundamentals of Machinery Design

Doctoral dissertation

Electric car battery leakage detection system

MSc, Eng. Grzegorz Wójcik

Dissertation advisor:
PhD, DSc, Eng. Piotr Przystałka, Associate Professor

Industry supervisor:
PhD, Eng. Wojciech Sebzda

Gliwice, 2023

Electric car battery leakage detection system


System wykrywania nieszczelności akumulatorów stosowanych w samochodach elektrycznych

Rozprawa doktorska – streszczenie

Autor: mgr inż. Grzegorz Wójcik
Promotor: dr hab. inż. Piotr Przyszałka, prof. PŚ
Opiekun z przemysłu: dr inż. Wojciech Sebzda
Politechnika Śląska, Wydział Mechaniczny Technologiczny
DIP Draexlmaier Engineering Polska Sp. z o.o.

Gwałtowny wzrost rynku pojazdów elektrycznych spowodował, że ze względu na coraz wyższe wymagania dotyczące mocy i gęstości energii źródła zasilania tego typu środków technicznych, pakiety akumulatorów litowo-jonowych znalazły się w centrum uwagi. Rzutuje to na szereg konsekwencji związanych z bezpieczeństwem ich eksploatacji, ponieważ akumulatory te powinny być eksploatowane w wąskim przedziale temperaturowym. Są one podatne na czynniki środowiskowe, warunki pracy i błędy produkcyjne. Z tego powodu nowoczesne pakiety akumulatorowe wykorzystują systemy zarządzania baterią (ang. Battery Management System, BMS) i systemy zarządzania ciepłem (ang. Battery Thermal Management System, BTMS) w celu zapobieżenia uszkodzeniom lub zbyt szybkiemu starzeniu się ogniw akumulatorowych. Stosowanie w/w ogniw poza przewidzianymi warunkami może skutkować różnymi uszkodzeniami. Pozornie niewielkie uszkodzenia mogą się z czasem pogłębiać oraz propagować na kolejne ogniwa, doprowadzając nawet do eksplozji [1-4].

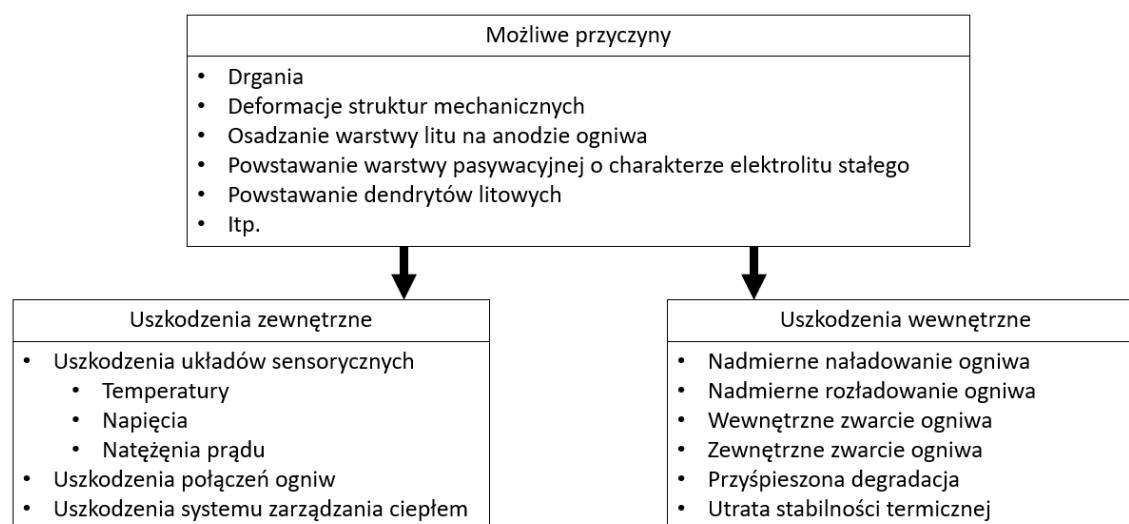
Celem niniejszej rozprawy doktorskiej jest opracowanie systemu detekcji nieszczelności dla chłodzonych zanurzeniowo pakietów akumulatorowych stosowanych w samochodach elektrycznych, wykorzystując polimerowy światłowodowy czujnik absorpcji fal zanikających oraz metody detekcji uszkodzeń bazujące na sztucznych sieciach neuronowych. Podejście to pozwala na wykorzystanie toru optycznego w miejscach wysokonapięciowych, niwelując główne wady obecnych rozwiązań, takie jak ekspozycja niskonapięciowych elementów układów BMS/BTMS na wyładowania elektrostatyczne oraz zakłócenia elektromagnetyczne (Rys. 1).



Rys. 1. Przykładowy sposób zastosowania opracowanego polimerowego czujnika światłowodowego

Mając na uwadze badania przemysłowe i prace rozwojowe zapoczątkowane w firmie DRÄXLMAIER w kontekście pakietów akumulatorowych z chłodzeniem zanurzeniowym zauważono, że nieszczelność tego typu układów może być spowodowana np. uszkodzeniem obudowy lub wymiennika ciepła i może skutkować wyciekami czynnika chłodzącego (np. oleju mineralnego) jak i wtargnięciem wody do wnętrza układu. Ponieważ system detekcji rozważanych uszkodzeń jest opracowywany z myślą o przemyśle motoryzacyjnym, założono że będzie on odporny na drogowe warunki środowiskowe.

Dodatkowo, przeprowadzony przegląd literaturowy [4-8] w zakresie samochodowych pakietów bateryjnych ujawnił obawy środowiska akademickiego co do prawidłowości aktualnego kierunku rozwoju systemów bateryjnych, który skupia się na obniżaniu kosztów wytworzenia i zwiększaniu ilości energii pozyskanej z pojedynczego ogniwa akumulatorowego, nie dokładając należytej uwagi ich prawidłowej eksploatacji. Zidentyfikowany został szereg uszkodzeń, jakim mogą podlegać samochodowe systemy bateryjne oraz przyczyn ich występowania (Rys. 2).



Rys. 2. Wewnętrzne i zewnętrzne uszkodzenia akumulatorów litowo-jonowych oraz ich przyczyny [4]

Uszkodzenia akumulatorów, zarówno na poziomie pakietu, modułów jak i pojedynczych ogniw, stanowią poważne ryzyko i mogą skutkować np. przegrzewaniem czy przyspieszoną degradacją ogniw. Mogą również prowadzić do katastrof w skutek zainicjowania reakcji łańcuchowej, prowadzącej do utraty stabilności termicznej pakietu akumulatorowego. Reakcja ta może zostać spowodowana nawet pozornie niewielkim uszkodzeniem (jak np. wtargnięcie wody), które może z biegiem czasu propagować i uszkadzać inne ogniwa. Konsekwencje takich kaskadowych zdarzeń w dużym pakiecie akumulatorowym mogą być poważne z powodu wydzielania dużych ilości ciepła i łatwopalnych gazów, skutkując gwałtownym wzrostem temperatury i ciśnienia. Powoduje to zwiększone ryzyko zapłonu i eksplozji [9]. Uszkodzenia inicjujące taką reakcję łańcuchową mogą przyjmować różną formę, jak np. wtargnięcia wody [10, 11], która gromadzi się w pakiecie akumulatorowym m.in. w skutek uszkodzonego wymiennika ciepła, i może powodować korozję oraz zwarcia w obszarach o wysokim napięciu. Właściwe projektowanie układów BMS i BTMS jest więc kluczowe dla zapewnienia bezpieczeństwa i trwałości systemu, zwłaszcza w kontekście pakietów akumulatorowych o wysokich wymogach dotyczących natężenia prądu ładowania i rozładowania. W celu wykrywania wycieku lub wtargnięcia cieczy aktualnie stosowane są głównie elektryczne czujniki konduktometryczne i pojemnościowe (w zależności od zastosowanego BTMS), które wykazują

pewne wady. Wady te są szczególnie istotne ze względu na stosowanie niskonapięciowych sygnałów elektrycznych w obszarach wysokonapięciowych. Chociaż sposób chłodzenia zanurzeniowego jest skomplikowany w konstrukcji, został on z powodzeniem wykorzystany w niskoseryjnych modelach pojazdów hybrydowych oraz elektrycznych, takich jak np. McLaren Speedtail, Mercedes AMG GT 63 S E Performance oraz Faraday Future FF91 [12-14]. W branży motoryzacyjnej, w miarę dojrzewania poziomu gotowości technologicznej, jednym z kroków jest wdrażanie nowej technologii do samochodów o niskim wolumenie przed jej wprowadzeniem do samochodów o wysokim wolumenie. Wdrożenie chłodzenia zanurzeniowego dla wyżej wymienionych pojazdów pozwoliło na zidentyfikowanie kształtującego się trendu, zwracając uwagę na potrzebę stosowania systemów detekcji nieszczelności.

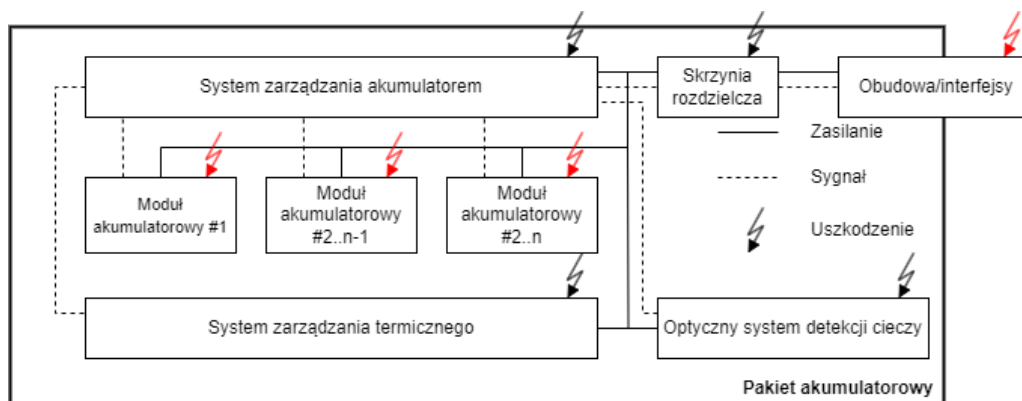
Przegląd literaturowy [4, 15-29] w zakresie metod diagnozowania w kontekście systemów bateryjnych pojazdów elektrycznych wykazał podział na metody bazujące na modelu obiektu oraz metody bezpośrednie. Metody diagnozowania stosowane przy podejściu pośrednim (z wykorzystaniem modelu obiektu) wykazują się mniejszymi wymaganiami dotyczącymi niezbędnych mocy obliczeniowych oraz szybkim czasem reakcji. Największą trudnością jest trudność w przygotowaniu modelu obiektu (np. w postaci zależności pomiędzy sygnałami wejściowymi oraz wyjściowymi). Dla akumulatorów pojazdów elektrycznych utworzenie modelu analitycznego jest wyzwaniem ze względu na skomplikowane własności elektrochemiczne ogniw litowo-jonowych oraz złożoną fizykę uszkodzenia. Modele uzyskane w drodze identyfikacji obejmują natomiast modele estymacji stanu, modele estymacji parametrów, analizę strukturalną, równania zgodności, modele neuronowe, rozmyte, neuronowo-rozmyte itd. Metody diagnozowania bezpośredniego dzielą się na metody bazujące na przetwarzaniu sygnałów zmiennych procesowych oraz metody oparte na wiedzy pozyskanej od ekspertów. Nie wymagają modelu obiektu, jednak niezbędny jest czasochłonny proces trenowania i znaczna ilość danych lub wiedza ekspercka dotycząca danego procesu/zjawiska. Metody przetwarzania danych wymagają dobrej jakości danych. Dotychczasowy przegląd literatury nie wykazał zbyt wielu zastosowań metod sztucznej inteligencji w obszarze czujników światłowodowych. Pojedyncze pozycje literaturowe zawierały przykłady wykorzystania sztucznych sieci neuronowych, w tym konwolucyjnych sieci neuronowych w celu klasyfikacji miejsc światłowodu, w których wystąpiły zaburzenia (ugięcia, zmiany temperatury). Metody sztucznej inteligencji znalazły natomiast zastosowanie np. przy estymacji pojemności akumulatora litowo-jonowego. Algorytmy te (będące często kombinacją różnych technik, jak np. RNN-LTSM) są zazwyczaj uruchamiane na urządzeniach BMS wchodzących w skład systemu bateryjnego. Znalezione pozycje literaturowe obejmują m.in. wykorzystanie nienadzorowanych technik uczenia maszynowego (GPR, Gaussian Process Regression) w celu diagnozowania degradacji systemu bateryjnego. Większość publikacji [4, 15] przedstawia rozwiązania we wczesnej fazie badań, wykorzystywane na podstawie danych symulacyjnych lub stosując prototypy systemów bateryjnych, odbiegające sprzętowo od docelowych systemów bateryjnych pojazdów elektrycznych oraz z pominięciem czynników takich jak np. warunki środowiskowe lub efekty zużycia mające wpływ na charakterystyki ogniwa litowo-jonowego.

Prace badawczo-rozwojowe w zakresie wytworzenia prototypu światłowodowego czujnika współczynnika refrakcji obejmowały szereg czynności, takich jak przegląd literaturowy w zakresie wykorzystania podobnych czujników w przemyśle motoryzacyjnym i lotniczym, technik pomiarowych, metod wytwarzania oraz oceny działania wytworzonego czujnika. Dokonany przegląd [30-34] wykazał, że światłowodowe czujniki polimerowe zostały wykorzystane w branży motoryzacyjnej, np. dla systemu ochrony pieszych oraz systemu detekcji przeszkody szyb elektrycznych. Ponieważ przemysł motoryzacyjny jest rodzajem branży, w którym prototypy i nowe pomysły nie są publikowane (o ile nie zostały wcześniej opatentowane), niewiele szczegółów na temat wyżej wymienionych aplikacji zostało znalezionych. Wyselekcjonowano zatem przemysł lotniczy do przeprowadzenia podobnego przeglądu, głównie ze względu na wyższe wymagania dot.

niezawodności niż w przypadku przemysłu motoryzacyjnego. W tym przypadku znaleziono więcej rozważań akademickich dotyczących wykorzystania polimerowych czujników światłowodowych, np. dla systemu mierzącego poziom paliwa oraz systemu mierzącego poziom odkształcenia kłapy samolotu. Na podstawie przeglądu stanu literatury i techniki [35] ustalono również sposób wyznaczania charakterystyk rozważanego typu czujnika. Jest on zgodny z najnowszymi badaniami i ma na celu ułatwienie interpretacji danych oraz ich przedstawianie w publikacjach dla innych naukowców i inżynierów. Na podstawie dokonanego przeglądu w zakresie technik pomiarowych [35-44] wyselekcjonowano światłowodowy czujnik absorpcji fali zanikającej ze względu na stosunkowo niewielkie koszty odpowiadającego układu sterującego i pomiarowego. Przegląd dostarczył również informacji na temat dostępnych technik wytwarzania. Produkcja czujników światłowodowych odbywa się dzięki wykorzystaniu metod opierających się o modyfikacje morfologiczne (szlifowanie, wiercenie, zwężanie, gięcie) oraz chemiczne (fotopolimeryzacja, osadzanie cienkich warstw, trawienie). Selekcja metody wytwarzania jest uzależniona od wybranej techniki pomiaru.

Przegląd literaturowy [35, 44] wykazał szereg rozwiązań otrzymywanych dzięki gięciu, szlifowaniu, zwężaniu, nawiercaniu światłowodu mikrootworami. Czujniki bazujące na pomiarze zmiany długości fali otrzymywane są np. w wyniku modyfikacji struktury światłowodu poprzez ekspozycję jego fragmentów na fale świetlne z zakresu podczerwieni lub ultrafioletu. W wyniku takiego zabiegu otrzymywane są tzw. siatki Bragga, siatki długookresowe, czy ukośne siatki Bragga, dzięki którym zachodzi interakcja pomiędzy określoną długością fali w przesyłanej wiązce świetlnej a mierzonym zjawiskiem (np. zmianą temperatury, naprężenia). Pomiar intensywności światła (a taki sposób jest wykorzystywany w przypadku polimerowego czujnika światłowodowego absorpcji fal zanikających) wymaga mniej zaawansowanego sprzętu produkcyjnego. W związku z tym możliwe było zaadaptowanie jednej z technik wykorzystujących narzędzia ściernie. Przeprowadzono szereg eksperymentalnych badań w zakresie charakterystyk wytworzonych czujników światłowodowych. Badania obejmowały m.in. analizę wpływu powtarzalności produkcyjnej i natężenia światła emitowanego przez nadajnik światłowodowy na uzyskaną czułość. Zbadano również powtarzalność produkcyjną, rejestrując czułość każdego z wytworzonych czujników światłowodowych. Dokonano również badań w komorze klimatycznej, sprawdzając odpowiedź czujnika w zakresie temperatur otoczenia od -40°C do $+85^{\circ}\text{C}$. Badania zostały szerzej opisane w artykule pt. „Experimental investigation of factors influencing the transmission capabilities of a low cost, side-polished evanescent wave absorption plastic optical fiber sensors” [45].

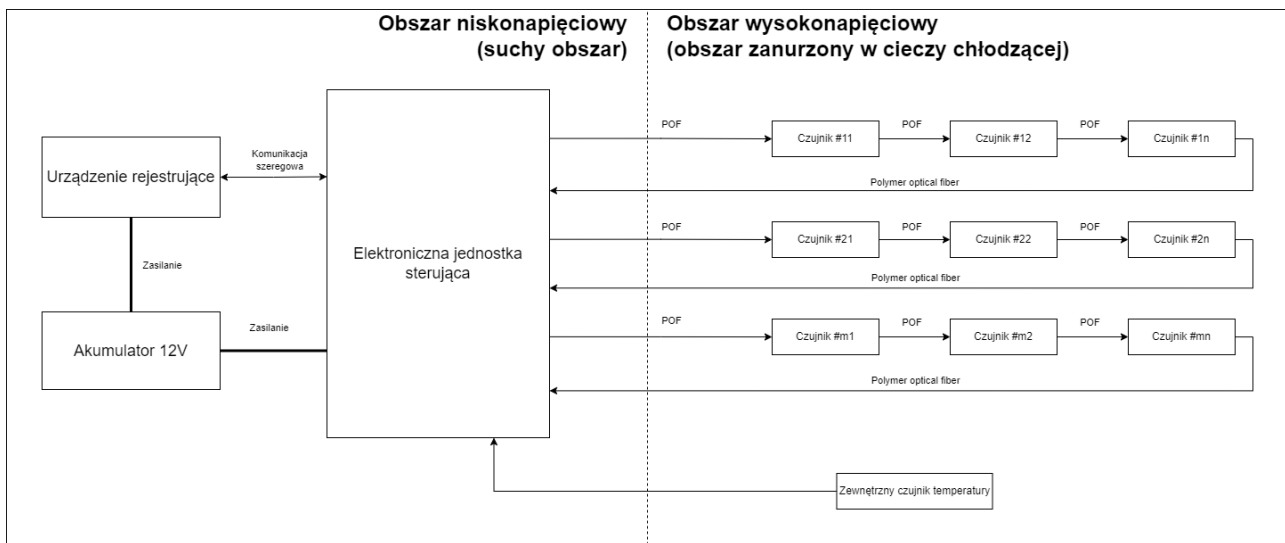
Obszerne prace badawcze w tym zakresie zostały zwieńczone wnioskami, na podstawie których została zaproponowana koncepcja optycznego systemu detekcji cieczy (ang. Optical Liquid Detection System, OLDS) i jego zastosowania do wykrywania nieszczelności pakietów akumulatorowych chłodzonych zanurzeniowo, stosowanych w samochodach elektrycznych (Rys. 3).



Rys. 3. Uproszczony schemat blokowy pakietu akumulatorowego samochodu elektrycznego, wykorzystującego system detekcji cieczy do wykrywania nieszczelności


Chociaż każdy z komponentów pakietu może ulec szeregowi uszkodzeń, w kontekście niniejszej pracy doktorskiej nieszczelność powoduje wyciek czynnika chłodzącego lub wtargnięcie cieczy do wewnątrz systemu. Detekcja tych uszkodzeń jest przedmiotem pracy. Uszkodzenia te zostały przedstawione kolorem czerwonym na Rys. 3. W kontekście samochodowych pakietów akumulatorowych, wyciek czynnika chłodzącego może w następstwie powodować różne zagrożenia, w zależności od architektury pakietu baterii (w szczególności wykorzystanego systemu zarządzania ciepłem). Jeśli ciecz chłodząca nie jest dielektrykiem, wówczas czynnik może prowadzić do zwarć. W przypadku dielektrycznych cieczy chłodzących (a takie są stosowane przy chłodzeniu zanurzeniowym), wyciek może w pierwszej kolejności skutkować pogorszonymi parametrami systemu zarządzania ciepłem, co długoterminowo może prowadzić do przegrzewania ogniw, ich przyspieszonej degradacji oraz utraty stabilności termicznej. W przypadku pakietów akumulatorowych z chłodzeniem zanurzeniowym, jednym z zagrożeń wynikających z wtargnięcia wody jest elektroliza. Obecność wody w systemie baterii może powodować reakcje chemiczne, zwiększając ciśnienie wewnątrz akumulatora i powodując jego rozszczelnienie. W skrajnych przypadkach nagromadzone gazy mogą ułatwiać powstawanie łuków elektrycznych. Przy niskich temperaturach, nagromadzona woda może również zmienić swój stan skupienia na stały. Fakt ten, w połączeniu z obecnością wymuszonego obiegu może powodować uszkodzenia innych podzespołów pakietu akumulatorowego w skutek krążących cząsteczek lodu.

Zaprojektowanie i wykonanie prototypu systemu detekcji wycieku czynnika chłodzącego lub/i wtargnięcia cieczy wymagało wiedzy dotyczącej inżynierii mechanicznej, w tym w obszarze budowy i eksploatacji elektrycznych pojazdów samochodowych, szczególnie w kontekście opracowania autorskich metod detekcji ww. uszkodzeń, bazujących na modelach neuronowych. Co więcej niezbędne było przeprowadzenie obszernych, interdyscyplinarnych prac badawczo-rozwojowych, ze względu na konieczność opracowania dedykowanej warstwy mechanicznej, sprzętowej, programowej oraz czujników światłowodowych. Prace te doprowadziły do wytworzenia polimerowego światłowodowego czujnika absorpcji fali zanikającej oraz opracowania dedykowanej platformy mechatronicznej (zgodnie z autorskim wynalazkiem [47] pt. "Optical liquid detection system", zgłoszonym 9 marca 2022 roku Biurze Własności Intelektualnej w Wielkiej Brytanii pod numerem GB2203308.8), służącej do rejestrowania danych w warunkach laboratoryjnych oraz drogowych dla systemu w stanie pełnej zdadności oraz przy celowo wprowadzonych uszkodzeniach (wyciek oleju, wtargnięcie wody). Projekt i wykonanie systemu detekcji zostały szczegółowo przedstawione w pracy, prezentując m.in. architekturę wraz z sformułowanymi wymaganiami funkcjonalnymi i niefunkcjonalnymi, gdzie określono wymagania m.in. takie jak opóźnienie detekcji uszkodzenia (maksymalnie 300 sekund), współczynnik poprawnie generowanych alarmów (minimalnie 80%) oraz fałszywych alarmów (maksymalnie 2%). Wymagania zostały dostosowane do wymagań przemysłu samochodowego, w szczególności pakietów akumulatorowych z chłodzeniem zanurzeniowym. Projekt i wykonanie systemu detekcji ww. uszkodzeń było procesem iteracyjnym, obejmującym co najmniej trzy różne wersje platformy mechatronicznej. Finalna architektura platformy, została przedstawiona na Rys. 4. Ponieważ pakiety akumulatorowe pojazdów elektrycznych są rozległymi, ciężkimi i kosztownymi urządzeniami, dla celów niniejszej pracy doktorskiej wykorzystywany system akumulatorowy został znacząco uproszczony do formy pojedynczego modułu akumulatorowego. W tym celu wykorzystano rzeczywistą obudowę modułu baterijnego (oznaczonego przez producenta jako HPB80) i wyposażono ją w opracowany system detekcji nieszczelności. Dla potrzeb tej rozprawy wyznaczono umowne obszary o niskim i wysokim napięciu. Jednak ze względów bezpieczeństwa, w trakcie badań nie wykorzystywano wysokiego napięcia, a system był zasilany baterią o nominalnym napięciu 12 V. Oprócz akumulatora zasilającego, obszar o niskim napięciu przewiduje wykorzystanie zaprojektowanej i wykonanej elektronicznej jednostki (ang. Electronics Control Unit, ECU) oraz gotowego rejestratora danych.



Rys. 4. Uproszczony schemat blokowy modułu akumulatorowego wykorzystującego system detekcji nieszczelności

Elektroniczna jednostka sterująca ma możliwość podłączenia do czterech polimerowych czujników światłowodowych oraz zewnętrznego czujnika temperatury (termistora). Światłowody polimerowe są prowadzone z suchego obszaru niskonapięciowego do obszaru wysokonapięciowego, zanurzonego w cieczy dielektrycznej (np. oleju mineralnym). Oprócz czujników światłowodowych, w obszarze wysokiego napięcia umieszczono również zewnętrzny czujnik temperatury. Dane pozyskane przez ten czujnik służą jedynie celom badawczo-rozwojowym i nie są używane przez opracowane metody detekcji uszkodzeń. Biorąc pod uwagę przedstawiony schemat blokowy, w zakresie niniejszej rozprawy było zaprojektowanie i wykonanie kompletnego sterownika ECU oraz czujnika światłowodowego. Wykonany system detekcji nieszczelności, zamontowany w module akumulatorowym został przedstawiony na Rys. 5.



Rys. 5. System detekcji nieszczelności bazujący na OLDS zamontowany wewnątrz modułu akumulatorowego

Dwa kluczowe komponenty systemu, tj. urządzenie rejestrujące dane (1) oraz sterownik systemu detekcji nieszczelności (2), zostały umieszczone w suchym, niskonapięciowym obszarze (3). Obszar uznawany za wysokonapięciowy (4) jest jednocześnie obszarem, w którym znajdowałyby się ogniwa akumulatorowe w pełni zanurzone w dielektrycznej cieczy, np. oleju mineralnym. W tej strefie celowo wprowadzane były uszkodzenia takie jak wyciek oleju oraz wtargnięcie wody. W strefie tej został umiejscowiony wytworzony polimerowy czujnik światłowodowy (5) oraz zewnętrzny termistor (7), odpowiedzialny za monitorowanie temperatury czynnika chłodzącego. W przypadku tej wersji zdecydowano się wykorzystać czujnik światłowodowy z jedną czułą częścią (6), zlokalizowaną w

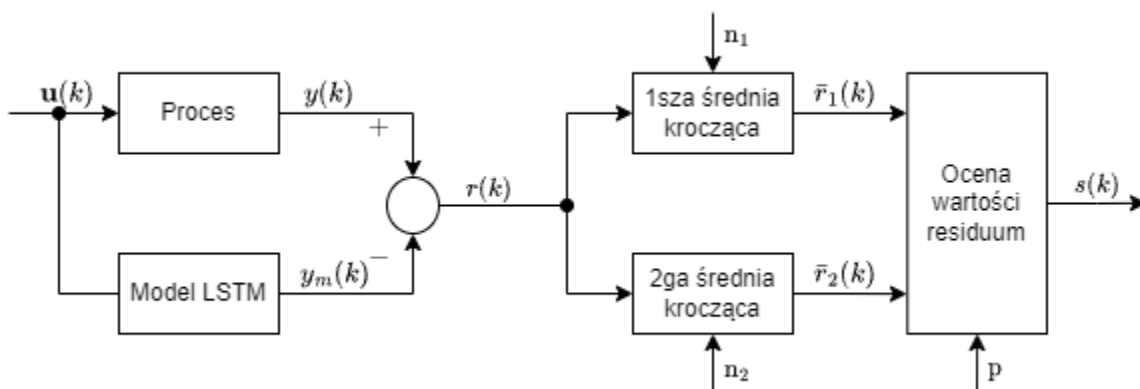
środku obszaru wysokonapięciowego. Ze względu na ograniczenia przestrzenne w obudowie modułu akumulatorowego, bateria zasilająca całość (o nominalnym napięciu 12 V) została umiejscowiona poza platformą mechatroniczną.

Właściwości optoelektroniczne i optomechaniczne zaprojektowanego systemu detekcji nieszczelności są zależne od wielu czynników, zwłaszcza w warunkach drogowych, np.:

- wahania temperaturowe mogą powodować zmianę współczynnika refrakcji dielektrycznego czynnika chłodzącego oraz mogą wpływać na natężenie światła emitowanego przez nadajniki światłowodowe,
- efekt starzenia może spowodować zmianę współczynnika refrakcji dla czynnika chłodzącego oraz zmianę natężenia światła emitowanego przez nadajniki światłowodowe,
- drgania, jakim podlegają komponenty w trakcie warunków drogowych mogą oddziaływać na optomechaniczne sprzężenie nadajników i odbiorników światłowodowych z podłączonym czujnikiem światłowodowym i powodować dodatkowy szum pomiarowy.

W związku z tym, niniejsza praca doktorska uwzględnia detekcję uszkodzeń przy użyciu metod bazujących na modelu, w którym takie czynniki są pośrednio brane pod uwagę. W pracy zostały utworzone metody detekcji uszkodzeń, które bazują na rekurencyjnych sieciach neuronowych, przydatnych do uczenia się długoterminowych zależności systemu w różnych warunkach otoczenia. Łącznie zaproponowano dwie metody. Pierwsza - metoda detekcji uszkodzenia przy użyciu sieci neuronowych Long Short-Term Memory (LSTM) (z dwoma różnymi podejściami do oceny residuów). Metoda ta została przetestowana i zweryfikowana przy użyciu zestawów danych uzyskanych w warunkach laboratoryjnych. Na podstawie uzyskanych wyników i wyciągniętych wniosków zaproponowano drugą metodę, mianowicie metodę detekcji uszkodzeń przy użyciu sieci neuronowych typu autoenkoder. Metoda ta wykorzystuje podejście nieco inne od typowego podejścia do wykrywania uszkodzeń, ponieważ do wykorzystywanego autoenkodera są dostarczane tylko sygnały zmiennych procesowych stanowiące odpowiedź systemu. Metoda ta została przetestowana i zweryfikowana przy użyciu końcowej wersji OLDS, która posłużyła do zbierania zestawów danych w warunkach drogowych. Do oceny zaproponowanych metod wykorzystano zestaw wskaźników jakości i złożoności modelu obiektu oraz zestaw wskaźników skuteczności metody detekcji.


Pierwsza z zaproponowanych metod (metoda detekcji uszkodzenia przy użyciu głębokich sieci neuronowych LSTM) wykorzystuje typowe podejście diagnostyki procesów oparte na modelu, w którym model wykorzystuje wejściowe i wyjściowe zmienne procesowe. Metoda została zaproponowana w dwóch wariantach, mając wspólny model LSTM, a różniących się sposobem oceny residuów oraz poziomem skomplikowania. Pierwszy wariant został przedstawiony na Rys. 6.



Rys. 6. Metoda detekcji uszkodzeń z wykorzystaniem sieci LSTM - pierwszy wariant oceny residuum


Dla tego schematu detekcji, ocena obliczonych residuów opiera się na analizie statystycznej, wykorzystującej dwie średnie ruchome i stały próg do generowania binarnego sygnału diagnostycznego. Podejście to charakteryzuje się nieskomplikowanym sposobem oceny residuów, co jest ważne z punktu widzenia oprogramowania dla urządzeń wbudowanych takich jak ECU.

Drugi z wariantów oceny residuum (Rys. 7) wykorzystuje dodatkowo model błędu (stosując płytkie sieci neuronowe z opóźnieniem czasowym TDNN), którego zadaniem jest oszacowywanie wartości residuum jakiego byłoby wyznaczone dla systemu w stanie pełnej zdadności. Sygnał ten jest następnie wykorzystywany do wyznaczania adaptacyjnych progów, na podstawie których generowany jest binarny sygnał diagnostyczny. Podejście to jest uważane za bardziej niezawodne, będąc jednocześnie bardziej wymagającym obliczeniowo.



Rys. 7. Metoda detekcji uszkodzeń z wykorzystaniem sieci LSTM – drugi wariant oceny residuum

Kolejna z zaproponowanych metod detekcji uszkodzeń (Rys. 8) wykorzystuje głębokie sieci neuronowe w postaci rekurencyjnego autoenkodera z warstwami GRU. Metoda ta jest bardziej praktyczną oraz mniej wymagającą obliczeniowo alternatywą dla pierwszej proponowanej metody, która pomimo swoich teoretycznych zalet dla systemu detekcji nieszczelności charakteryzuje się jednak wysoką złożonością obliczeniową.



Rys. 8. Metoda detekcji uszkodzeń z wykorzystaniem sieci rekurencyjnego autoenkodera

Proponowana metoda RAE-GRU wykorzystuje mniej złożone warstwy GRU (w porównaniu do warstw LSTM), co minimalizuje złożoność obliczeniową oraz wymagania dotyczące pamięci. Jest to szczególnie istotne dla systemów wbudowanych o ograniczonych zasobach. Dodatkowo, podejście RAE-GRU zachowuje zdolność do modelowania długoterminowych zależności szeregów czasowych zmiennych procesowych.


Ocenę działania modeli neuronowych procesów można prowadzić na wiele sposobów. W rozprawie doktorskiej do oceny modelu obiektu wykorzystano miary *ex post* takie jak średni bezwzględny błąd (MAE), średni bezwzględny błąd procentowy (MAPE), błąd średniokwadratowy

(MSE), pierwiastek z błędu średniokwadratowego (RMSE) oraz znormalizowany błąd RMSE (nRMSE). Przytoczone miary oceny poprawności odwzorowania dynamiki procesu nie zawsze są dobrą podstawą oceny jakości uzyskanego modelu. Często w ocenie modelu niezbędne jest również uwzględnienie jego złożoności. Dlatego w rozprawie posłużono się również miarami takimi jak kryterium informacyjne Akaike (AIC), kryterium Schwarza (BIC) oraz kryterium Hannana i Quinna (PHI).

Ocena merytoryczno-techniczna poprawności części decyzyjnej systemu detekcji uszkodzeń została zrealizowana wykorzystując trzy miary: wskaźnik fałszywych alarmów, wskaźnik poprawnie generowanych alarmów oraz opóźnienie detekcji uszkodzenia.

Ważnym etapem pracy było przeprowadzenie badań weryfikacyjnych, sprawdzając działanie zaprojektowanych platform mechatronicznych i weryfikując działanie zaproponowanych metod detekcji uszkodzeń. Wykonane platformy posłużyły do zebrania zestawów danych w celu późniejszej implementacji zaproponowanych metod (w trybie offline) oraz ich oceny stosując wybrane wskaźniki. Przygotowano plan badań weryfikacyjnych, który został podzielony na dwa główne etapy: wstępne badania w warunkach laboratoryjnych oraz zasadnicze badania w warunkach drogowych.

Wstępne badania przeprowadzone w warunkach laboratoryjnych obejmowały utworzenie prototypu stanowiska badawczego (Rys. 9), akwizycję danych, implementację pierwszej z zaproponowanych metod detekcji, tj. metodę detekcji uszkodzeń z wykorzystaniem sieci LSTM i dwóch sposobów oceny residuum.



Rys. 9. Stanowisko badawcze wykorzystane w trakcie badań weryfikacyjnych przeprowadzonych w warunkach laboratoryjnych

Pierwsza faza obejmowała konfigurację komponentów systemu, m.in. wytworzonego czujnika światłowodowego, opracowanej platformy mechatronicznej, urządzeń pomiarowych oraz dodatkowych narzędzi do symulowania uszkodzeń, takich jak pompa perystaltyczna (do symulowania wycieku oleju) oraz mieszadło magnetyczne (do symulowania ruchu pojazdu). Stanowisko badawcze posłużyło do zgromadzenia danych procesowych zarówno w stanie pełnej zdatności, jak i przy stanach technicznych odpowiadających wyciekowi oleju i wtargnięciu wody. Przeprowadzono łącznie 25 eksperymentów. Dla stanu pełnej zdatności (F0) przewidziano 10 eksperymentów. Dla stanu wycieku oleju (F1) również przewidziano 10 eksperymentów, jednak wielkość uszkodzenia (stężenie wody w powstałej emulsji) była zmienna. Dla stanu wtargnięcia wody (F2) przewidziano 5 eksperymentów, również o różnym poziomie uszkodzenia. Dla każdego eksperymentu przewidziano indywidualne czasy wprowadzenia uszkodzenia (t_1), włączenia (t_2) i wyłączenia (t_3) mieszadła magnetycznego oraz różne wielkości uszkodzenia (Q_1). Parametry każdego z przeprowadzonych eksperymentów zostały przedstawione w Tab. 1. Łącznie zarejestrowano 337659 rekordów danych, co odpowiada około 55 minutom dla wszystkich eksperymentów (częstotliwość próbkowania wynosiła 100 Hz). Zebrane dane zostały podzielone na trzy kategorie: dane trenujące (eksperymenty 1-4, 6-9), dane testujące (eksperymenty 5 i 10) oraz weryfikacyjne (eksperymenty 11-25).

Tab. 1. Zestawienie przeprowadzonych eksperymentów w warunkach laboratoryjnych

ID eksp.	Typ danych	ID stanu tech.	Opis	Wielk. uszk. [%]	Q_1 [ml]	t_1 [s]	t_2 [s]	t_3 [s]	t_{tot} [s]
1	Trenujące	F0	Pełna zdatność 1	-	-	-	-	-	53
2	Trenujące	F0	Pełna zdatność 2	-	-	-	-	-	42
3	Trenujące	F0	Pełna zdatność 3	-	-	-	-	-	30
4	Trenujące	F0	Pełna zdatność 4	-	-	-	-	-	44
5	Testujące	F0	Pełna zdatność 5	-	-	-	-	-	175
6	Trenujące	F0	Pełna zdatność (mieszany) 1	-	-	-	12	57	75
7	Trenujące	F0	Pełna zdatność (mieszany) 2	-	-	-	11	67	82
8	Trenujące	F0	Pełna zdatność (mieszany) 3	-	-	-	23	67	69
9	Trenujące	F0	Pełna zdatność (mieszany) 4	-	-	-	-	48	77
10	Testujące	F0	Pełna zdatność (mieszany) 5	-	-	-	7	30	72
11	Weryfikacyjne	F1	Wyciek oleju 1	100	300	45	-	-	174
12	Weryfikacyjne	F1	Wyciek oleju 2	100	300	7	-	-	148
13	Weryfikacyjne	F1	Wyciek oleju 3	50	150	42	-	-	140
14	Weryfikacyjne	F1	Wyciek oleju 4	100	300	17	-	-	172
15	Weryfikacyjne	F1	Wyciek oleju 5	100	300	23	-	-	207
16	Weryfikacyjne	F2	Wtargnięcie wody 1	9	30	55	15	175	175
17	Weryfikacyjne	F2	Wtargnięcie wody 2	14	20	17	0	122	161
18	Weryfikacyjne	F2	Wtargnięcie wody 3	14	-	-	17	107	150
19	Weryfikacyjne	F2	Wtargnięcie wody 4	14	-	-	0	89	142
20	Weryfikacyjne	F2	Wtargnięcie wody 5	14	-	-	4	74	166
21	Weryfikacyjne	F2	Wtargnięcie wody 6	21	30	18	0	88	154
22	Weryfikacyjne	F2	Wtargnięcie wody 7	21	-	-	19	64	202
23	Weryfikacyjne	F2	Wtargnięcie wody 8	21	-	-	24; 69	49; 99	180
24	Weryfikacyjne	F2	Wtargnięcie wody 9	30	50	11	0	96	149
25	Weryfikacyjne	F2	Wtargnięcie wody 10	30	130	-	19	65	327

Uszkodzenia były wprowadzane w kontrolowany sposób, przy użyciu wcześniej wspomnianej pompy perystaltycznej oraz mieszadła magnetycznego. Zgromadzone dane dostarczyły kluczowych informacji na temat zachowania systemu w stałych warunkach środowiskowych (w temperaturze pokojowej około 25°C oraz wilgotności powietrza w przedziale 40-60%). Zgromadzone dane zostały użyte do weryfikacji poprawności pierwszej metody detekcji uszkodzeń. Proces ten obejmował projektowanie, dobór parametrów oraz trenowanie i testowanie modelu LSTM. Finalna struktura głębokiej sieci neuronowej dla zaproponowanej metody została przedstawiona na Rys. 10. Struktura składała się z warstwy wejściowej przyjmującej sekwencyjne dane wejściowe w postaci wektorów o dwóch wymiarach, pierwszej warstwy LSTM z 55 ukrytymi neuronami, warstwy dropout, drugiej warstwy LSTM (identycznej w konfiguracji do pierwszej warstwy LSTM), w pełni połączonej warstwy z jednym neuronem wyjściowym oraz warstwy wyjściowej realizującej zadanie regresji.

	Name	Type	Activations	Learnable Properties	Number of Learnables
SequenceInputLayer	1 SequenceInputLayer Sequence input with 2 dimensions	Sequence Input	$2(C) \times 1(B) \times 1(T)$	-	0
LSTM_layer_1	2 LSTM_layer_1 LSTM with 55 hidden units	LSTM	$55(C) \times 1(B) \times 1(T)$	InputWeights 220×2 RecurrentWeights 220×55 Bias 220×1	12760
DropoutLayer	3 DropoutLayer 1% dropout	Dropout	$55(C) \times 1(B) \times 1(T)$	-	0
LSTM_layer_2	4 LSTM_layer_2 LSTM with 55 hidden units	LSTM	$55(C) \times 1(B) \times 1(T)$	InputWeights 220×55 RecurrentWeights 220×55 Bias 220×1	24420
FullyConnectedLayer	5 FullyConnectedLayer 1 fully connected layer	Fully Connected	$1(C) \times 1(B) \times 1(T)$	Weights 1×55 Bias 1×1	56
RegressionOutput	6 RegressionOutput mean-squared-error with response 'Response'	Regression Output	$1(C) \times 1(B) \times 1(T)$	-	0

Rys. 10. Struktura głębokiej sieci neuronowej LSTM zastosowana do weryfikacji metody detekcji uszkodzeń w warunkach laboratoryjnych

Dla pierwszego wariantu metody przyjęto parametry $n_1 = 300$ i $n_2 = 150$ oraz próg aktywacji sygnału diagnostycznego $p = 0.0015$. Dla wariantu metody z modelem błędu, przyjęto strukturę sieci neuronowej TDNN złożonej z warstwy wejściowej, warstwy opóźnienia czasowego (do 50 kroków wstecz), warstwy dropout, ukrytej warstwy z 20 ukrytymi neuronami oraz warstwy wyjściowej z liniową funkcją aktywacji. Metoda ta wymagała podania wartości średniej \bar{r} oraz odchylenia standardowego σ_r . Na podstawie danych trenujących wyznaczono $\bar{r} = -0,0075$ oraz $\sigma_r = 0,006$. Poziom istotności t_{α}^{\pm} potrzebny do wyznaczania progów adaptacyjnych $p^{\pm}(k)$, został określony jako $t_{\alpha}^{+} = 2,3$ oraz $t_{\alpha}^{-} = 0,05$. Działanie metody wg schematów pokazanych na Rys. 6 i Rys. 7 zostało ocenione biorąc pod uwagę zarówno wskaźniki jakości i złożoności modelu obiektu, oraz metryk oceniających poprawność działania metody detekcji uszkodzeń. Uzyskane wskaźniki fałszywych alarmów oraz poprawnie generowanych alarmów zostały przedstawione w Tab. 2.

Tab. 2. Zestawienie wskaźników skuteczności dwóch wariantów metody detekcji uszkodzeń wykorzystującej sieci LSTM

ID eksp.	Opis danych	r_{td}		r_{fd}		r_{td}^*		Wielkość uszkodzenia
		Wariant I	Wariant II	Wariant I	Wariant II	Wariant I	Wariant II	
5	F0 - 5	-	-	0.000	0.019	-	-	-
10	F0 (mieszany) - 5	-	-	0.000	0.000	-	-	-
11	F1 - 1	0.375	0.405	0.000	0.001	-	-	100%
12	F1 - 2	0.372	0.466	0.000	0.003	-	-	100%
13	F1 - 3	0.047	0.305	0.000	0.013	-	-	50%
14	F1 - 4	0.411	0.551	0.011	0.096	-	-	100%
15	F1 - 5	0.362	0.614	0.013	0.059	-	-	100%
16	F2 - 1	0.034	0.007	0.000	0.002	0.034	0.007	9%
17	F2 - 2	0.124	0.010	-	-	0.148	0.014	14%
18	F2 - 3	0.143	0.198	-	-	0.206	0.152	14%
19	F2 - 4	0.154	0.603	-	-	0.224	0.553	14%
20	F2 - 5	0.125	0.573	-	-	0.219	0.467	21%
21	F2 - 6	0.388	0.753	-	-	0.509	0.751	21%
22	F2 - 7	0.154	0.632	-	-	0.541	0.728	21%
23	F2 - 8	0.291	0.736	-	-	0.568	0.763	21%
24	F2 - 9	0.556	0.689	-	-	0.649	0.708	30%
25	F2 - 10	0.150	0.784	-	-	0.452	0.790	30%

Uzyskane wyniki podkreśliły znaczenie jakości danych wykorzystujących przez modele neuronowe. Dla pakietów akumulatorowych samochodów elektrycznych z chłodzeniem zanurzeniowym ważne jest odpowiednie umiejscowienie światłowodowego czujnika współczynnika

refrakcji, aby uzyskać wartościowe dane uczące. W przypadku wycieku oleju czujniki powinny być umieszczone w górnej części pakietu baterii, aby czujnik mógł jak najszybciej dostrzec zmianę rodzaju ośrodka, w którym się znajduje. Ponadto, pakiet akumulatorowy powinien być zaprojektowany tak, aby posiadać dodatkowe czujniki umieszczone w miejscach, gdzie najprawdopodobniej wystąpi wtargnięcie wody. Na przykład, dodatkowe czujniki można umieścić w dolnych częściach, aby skutecznie wykryć gromadzącą się wodę w trakcie spoczynku pojazdu. Innym przykładem byłoby umieszczenie czujników światłowodowych w pobliżu wymiennika ciepła, gdzie występuje zwiększone prawdopodobieństwo wtargnięcia wody, np. w skutek rozszczelnienia układu (w skutek różnych współczynników rozszerzalności cieplnej wykorzystanych materiałów). Przeprowadzone badania pozwoliły określić zmienność symulowanych uszkodzeń w czasie. Zostały one zaklasyfikowane jako nagłe dla wycieku oleju i sporadyczne (ang. intermittent) dla wtargnięcia wody. Jeśli objętość przedostającej się wody nie jest wystarczająca, aby zetknąć się z czujnikiem światłowodowym w warunkach spoczynku pojazdu, symptomy tego uszkodzenia będą uwiidaczniać się głównie podczas ruchu pojazdu (lub w przypadku badań przeprowadzonych w warunkach laboratoryjnych - podczas mieszania).

Oba sposoby oceny residuów bazowały na tym samym modelu LSTM. Pierwsze podejście oceny residuów wykorzystywało analizę statystyczną, opartą na krótkoterminowych i długoterminowych średnich kroczących. Sposób ten wykazał ograniczoną skuteczność dla uszkodzeń o mniejszej amplitudzie oraz większą skuteczność detekcji dla nagłych zmian oraz warunków mieszania, symulujących ruch pojazdu. Druga technika oceny residuów, wykorzystująca model błędu zrealizowany w postaci płytkiej sieci TDNN oraz będąca bardziej wymagająca obliczeniowo, wykazała znacząco lepsze wyniki we wszystkich przypadkach, a różnica w jej skuteczności diagnozowania pomiędzy warunkami spoczynku a mieszania była znacznie niższa.

Wyniki uzyskane z wykorzystaniem pierwszej zaproponowanej metody detekcji uszkodzeń wykorzystującej sieci LSTM były przedmiotem prezentacji w trakcie „15th International Conference on Diagnostics of Processes and Systems” (DPS2022, Gdańsk) i zostały opublikowane jako rozdział pt. „LSTM model-based fault detection for electric vehicle’s battery packs” w monografii zaautowanej „Intelligent and safe computer systems in control and diagnostics” pod redakcją Zdzisława Kowalczyka w Lecture Notes in Networks and Systems, 2023, wydawnictwa Springer [46]. Badania przeprowadzone w warunkach laboratoryjnych obejmowały niewielką część czynników, jakim może podlegać system w trakcie eksploatacji. Na co dzień pojazdy są narażone na szeroki zakres temperatury pracy, drgania, starzenie się komponentów itp. Wyniki i wnioski pozyskane w trakcie tej części badań zostały uwzględnione przy projektowaniu docelowej platformy mechatronicznej, wykorzystywanej w trakcie warunków drogowych. Na bazie wniosków została również zaproponowana druga metoda detekcji uszkodzeń, tj. metoda detekcji uszkodzeń bazująca na głębokiej sieci typu autoenkoder.

Celem zasadniczego etapu badań weryfikacyjnych było zastosowanie finalnej wersji opracowanej platformy mechatronicznej do zgromadzenia danych w warunkach drogowych oraz wykorzystanie tych danych do weryfikacji metody detekcji uszkodzeń, bazującej na głębokiej sieci neuronowej typu autoenkoder. Warunki drogowe obejmowały szeroką gamę rzeczywistych scenariuszy, w tym drgania pochodzące od układu jezdnego oraz szeroki zakres temperatur otoczenia wynikających ze zmiany pogody. Pojazd z zamontowanym systemem detekcji nieszczelności (Rys. 11) był eksploatowany w typowy dla niego sposób przez całą fazę testowania. Testy były przeprowadzane na Śląsku, a w ich trakcie nie były stosowane żadne konkretne wzorce jazdy, co dodatkowo odwzorowywało scenariusze rzeczywiste. Testy były prowadzone przez kilka miesięcy, obejmując okres od grudnia 2022 do maja 2023, uwzględniając w ten sposób wahania temperaturowe, naturalne zużywanie się komponentów optoelektronicznych oraz typowe zakłócenia towarzyszące działaniu układów pomiarowych w warunkach rzeczywistych.



Rys. 11. Stanowisko badawcze zastosowane w trakcie eksperymentów przeprowadzonych w warunkach drogowych

Podejście to zapewniło wyższy stopień praktyczności wykonywanych badań oraz umożliwiło sprawdzenie działania systemu w mniej przewidywalnym środowisku. Dodatkowo, każdy zestaw danych był obszerny pod względem horyzontu czasowego, uwzględniając różnorodne warunki eksploatacyjne. Zaproponowany sposób prowadzenia czynnego eksperymentu diagnostycznego dostarczył w ten sposób unikalne zestawy danych treningowych, testowych i weryfikacyjnych, które były pozyskane zarówno w stanie spoczynku, jak i ruchu pojazdu.

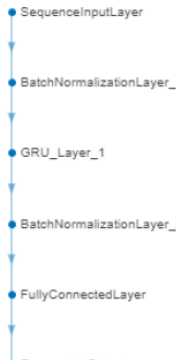
W stanie pełnej zdatności (F0) obiekt diagnozowania był wypełniony olejem mineralnym o objętości 16500 ml. Dane dla tego stanu technicznego zostały zarejestrowane w pierwszej kolejności. Następnie, zarejestrowane zostały sygnały dla obiektu w stanie wycieku oleju (F1), a uszkodzenie zostało zasymulowane poprzez wyciek oleju o objętości Q_1 . Stan wtargnięcia wody został zasymulowany jako ostatni, po zakończeniu eksperymentów w stanie F1. Objętość wody Q_1 wprowadzana była sekwencyjnie w zmiennych ilościach. Po wtargnięciu danej objętości wody, woda ta pozostawała w zbiorniku do dalszych eksperymentów i kumulowała się z każdym kolejnym wtargnięciem wody. Parametryczne podsumowanie zarejestrowanych zestawów danych zostało przedstawione w Tab. 3.

Tab. 3. Zestawienie przeprowadzonych eksperymentów w warunkach drogowych

ID eksp.	Typ danych	ID stanu tech. ID	Opis	Wielk. uszk. [%]	Q_1 [ml]	t_1 [min]	t_2 [min]
1	Weryfikacyjne	F0	Pełna zdatność 0	-	-	2596	104
2	Weryfikacyjne	F0	Pełna zdatność 1	-	-	1873	127
3	Weryfikacyjne	F0	Pełna zdatność 2	-	-	3468	274
4	Testujące	F0	Pełna zdatność 3	-	-	3623	176
5	Trenujące	F0	Pełna zdatność 4	-	-	1061	70
6	Trenujące	F0	Pełna zdatność 5	-	-	907	51
7	Weryfikacyjne	F0	Pełna zdatność 6	-	-	562	-
8	Weryfikacyjne	F1	Wyciek oleju 1	90	15000	1692	51
9	Weryfikacyjne	F1	Wyciek oleju 2	90	15000	211	15
10	Weryfikacyjne	F1	Wyciek oleju 3	90	15000	726	27
11	Weryfikacyjne	F1	Wyciek oleju 4	90	15000	1932	89
12	Weryfikacyjne	F1	Wyciek oleju 5	90	15000	1299	11
13	Weryfikacyjne	F2	Wtargnięcie wody 1	0.3	50	684	65
14	Weryfikacyjne	F2	Wtargnięcie wody 2	0.3	50	860	10
15	Weryfikacyjne	F2	Wtargnięcie wody 3	0.9	150	344	24
16	Weryfikacyjne	F2	Wtargnięcie wody 4	0.9	150	1098	91
17	Weryfikacyjne	F2	Wtargnięcie wody 5	1.8	300	122	10
18	Weryfikacyjne	F2	Wtargnięcie wody 6	1.8	300	31	27
19	Weryfikacyjne	F2	Wtargnięcie wody 7	1.8	300	62	26
20	Weryfikacyjne	F2	Wtargnięcie wody 8	1.8	300	221	21
21	Weryfikacyjne	F2	Wtargnięcie wody 9	1.8	300	42	32

Łącznie przeprowadzono 21 eksperymentów: 7 eksperymentów dla stanu pełnej zdatności, 5 eksperymentów dla stanu wycieku oleju i 9 eksperymentów dotyczących stanu wtargnięcia wody. Zarejestrowano łącznie 140532540 rekordów danych, które odpowiadają blisko 390 godzinom badań z różnymi stanami technicznymi obiektu będącego przedmiotem badań. Parametr Q_1 reprezentuje wielkość uszkodzenia. W przypadku uszkodzenia F1 parametr Q_1 oznacza objętość oleju, który wyciekł dla danego eksperymentu. Horyzont czasowy każdego zestawu danych (w minutach) został przedstawiony parametrem t_1 , natomiast t_2 reprezentuje łączny czas, w którym pojazd był w ruchu. Czas ten został określony na etapie post-processingu na podstawie zarejestrowanych odczytów z czujnika przyspieszeń.

Finalna struktura głębokiej sieci neuronowej RAE-GRU jest wynikiem procedury systematycznego przeszukiwania, w trakcie której sprawdzano różne konfiguracje, zmieniając parametry takie jak liczba warstw GRU wraz z liczbą odpowiadających im neuronów ukrytych. Mając na uwadze zasadę, że prostsze modele są zazwyczaj mniej podatne na przetrenowanie i mogą lepiej odwzorowywać testowe sygnały zmiennych procesowych, wybrano strukturę sieci neuronowej przedstawioną na Rys. 12.



	Name	Type	Activations	Learnable Properties	Number of Learnables
1	SequenceInputLayer Sequence input with 5 dimensions	Sequence Input	$5(C) \times 1(B) \times 1(T)$	-	0
2	BatchNormalizationLayer_1 Batch normalization with 5 channels	Batch Normalization	$5(C) \times 1(B) \times 1(T)$	Offset 5×1 Scale 5×1	10
3	GRU_Layer_1 GRU with 3 hidden units	GRU	$3(C) \times 1(B) \times 1(T)$	InputWeights 9×5 RecurrentWeights 9×3 Bias 9×1	81
4	BatchNormalizationLayer_2 Batch normalization with 3 channels	Batch Normalization	$3(C) \times 1(B) \times 1(T)$	Offset 3×1 Scale 3×1	6
5	FullyConnectedLayer 5 fully connected layer	Fully Connected	$5(C) \times 1(B) \times 1(T)$	Weights 5×3 Bias 5×1	20
6	RegressionOutput mean-squared-error with response 'Response'	Regression Output	$5(C) \times 1(B) \times 1(T)$	-	0

Rys. 12. Wybrana struktura głębokiej sieci neuronowej RAE-GRU zastosowana do oceny metody detekcji uszkodzeń

Wybrany model neuronowy umożliwił odtworzenie sygnału wyjściowego z czujnika POF z dokładnością ocenioną za pomocą wskaźnika MAE wynoszącego 1,028 oraz MAPE równego 0,992%, co wskazuje na niewielkie odchylenia od rzeczywistych wartości. Błędy RMSE i MSE były równe odpowiednio 1,30 i 1,70, co sugeruje, że ich większe wartości były karane. Wartości kryteriów informacyjnych AIC i BIC wskazały model najlepiej dostosowany pod względem złożoności. Dla zaproponowanej metody wyznaczono $\bar{r} = 0.133478$ oraz $\sigma_r = 1.425754$. Poziom istotności t_α potrzebny do wyznaczania progów decyzyjnych p^\pm przyjęto jako 24. Dla bloku oceny residuum, przyjęto liczbę przekroczonych progów $m_f = 3$ oraz czas trwania przekroczonych progów $P = 5$ (co przekłada się na 120 sekund przy aktualnej częstotliwości generowania sygnału diagnostycznego). Podobnie jak poprzednio, skuteczność działania zaproponowanej metody została oceniona biorąc pod uwagę nie tylko jakość i złożoność modelu ale również poprawność generowania sygnałów diagnostycznych. Uzyskane wskaźniki fałszywych alarmów, poprawnie generowanych alarmów oraz opóźnienia detekcji zostały przedstawione w Tab. 4. Wyniki pokazują, że progi górne i dolne zostały ustawione odpowiednio, ponieważ wygenerowane residua nie przekraczają ich w stanie pełnej zdatności, skutkując wskaźnikiem fałszywych alarmów na poziomie 0%. Uzyskane wyniki potwierdzają, że zaproponowany system detekcji nieszczelności bazujący na OLDS wyposażonym w czujnik polimerowy czujnik światłowodowy absorpcji fal zanikających oraz autorskich metodach detekcji może być używany do wykrywania wycieku oleju oraz wtargnięcia wody.

Przeprowadzone kompleksowe testy udowodniły, że zaprojektowany i zbudowany system spełnia zdefiniowane wymagania funkcjonalne i нефункционаłne. Biorąc pod uwagę stosunkowo małe wartości generowanych residuów (na poziomie 1-2% sygnału zarejestrowanego przez czujnik światłowodowy) dla stanu pełnej zdatności, można stwierdzić, że model RAE-GRU skutecznie nauczył się długoterminowych zależności, które system rejestrował w warunkach drogowych. Działanie metody detekcji uszkodzeń bazującej na tym modelu wskazuje zerowe wskaźniki fałszywych alarmów dla wszystkich zgromadzonych zestawów danych, niezależnie od przebiegu eksperymentu mającego na celu uzyskanie określonego stanu technicznego. Skuteczność zaproponowanej metody detekcji uszkodzeń jest skorelowana z wielkością uszkodzenia. Wskaźnik prawidłowych alarmów był wyznaczany dla przebiegów sygnałów rejestrowanych w trakcie ruchu pojazdu, ze względu na brak podzespołów do wymuszania obiegu cieczy stosowanych w docelowych warunkach eksploatacji obiektu diagnozowania. Wykorzystana obudowa nie była projektowana z myślą o detekcji cieczy, a jej konstrukcja nie przewiduje miejsca, w którym mogą się gromadzić cząsteczki wody z powstałej emulsji w trakcie spoczynku samochodu. Z tego względu czujnik światłowodowy został zamontowany w najbardziej odpowiednim miejscu u podstawy akumulatora, które jednak nie jest jego najniższym miejscem. Umieszczenie to mogło prowadzić do ograniczeń w czułości systemu detekcji w pewnych warunkach. W przypadku wtargnięcia wody oraz warunków spoczynkowych samochodu, ilość cząsteczek wody musi być wystarczająco duża aby zetknąć się z czujnikiem światłowodowym. W przeciwnym wypadku, w trakcie spoczynku pojazdu, ta bardzo niewielka ilość wody w oleju może zostać niezauważona przez system detekcji.

Tab. 4. Zestawienie wartości wskaźników skuteczności metody detekcji uszkodzeń bazującej na głębokiej sieci RAE-GRU

ID eksp.	ID stanu tech.	Opis	\bar{r}_{fd}	\bar{r}'_{td}	\bar{l}'_{dt} [s]	Wielk. uszk. [%]
1	F0	Pełna zdatność 0	0.000	-	-	-
2	F0	Pełna zdatność 1	0.000	-	-	-
3	F0	Pełna zdatność 2	0.000	-	-	-
4	F0	Pełna zdatność 3	0.000	-	-	-
5	F0	Pełna zdatność 4	-	-	-	-
6	F0	Pełna zdatność 5	-	-	-	-
7	F0	Pełna zdatność 6	0.000	-	-	-
8	F1	Wyciek oleju 1	0.000	0.609	133	90
9	F1	Wyciek oleju 2	0.000	0.972	25	90
10	F1	Wyciek oleju 3	0.000	0.797	160	90
11	F1	Wyciek oleju 4	0.000	0.800	170	90
12	F1	Wyciek oleju 5	0.000	0.678	53	90
13	F2	Wtargnięcie wody 1	0.000	0.000	-	0.3
14	F2	Wtargnięcie wody 2	0.000	0.000	-	0.3
15	F2	Wtargnięcie wody 3	0.000	0.000	-	0.9
16	F2	Wtargnięcie wody 4	0.000	0.086	2100	0.9
17	F2	Wtargnięcie wody 5	0.000	0.796	48	1.8
18	F2	Wtargnięcie wody 6	0.000	0.969	50	1.8
19	F2	Wtargnięcie wody 7	0.000	0.882	185	1.8
20	F2	Wtargnięcie wody 8	0.000	0.889	140	1.8
21	F2	Wtargnięcie wody 9	0.000	0.931	68	1.8

Gwałtowny wzrost rynku pojazdów elektrycznych spowodował, że ze względu na coraz wyższe wymagania dotyczące mocy i gęstości energii pakiety akumulatorów litowo-jonowych znalazły się w centrum uwagi. Rzutuje to jednak na szereg konsekwencji związanych z bezpieczeństwem ich eksploatacji. Akumulatory te powinny być eksploatowane w wąskim przedziale temperaturowym. Są

one podatne na czynniki środowiskowe, warunki pracy i błędy produkcyjne. Z tego powodu nowoczesne pakiety akumulatorowe wykorzystują systemy zarządzania baterią i termiczne systemy zarządzania w celu zapobieżenia uszkodzeniom lub zbyt szybkiemu starzeniu się ogniw akumulatorowych.

Uszkodzenia akumulatorów, zarówno na poziomie pakietu i modułów jak i pojedynczych ogniw, stanowią poważne ryzyko i mogą skutkować np. przegrzewaniem czy przyśpieszoną degradacją ogniw. Mogą również prowadzić do katastrof w skutek zainicjowania reakcji łańcuchowej, prowadzącej do utraty stabilności termicznej pakietu akumulatorowego. Taka reakcja może zostać spowodowana nawet pozornie niewielkim uszkodzeniem, które może z biegiem czasu propagować i uszkadzać inne ogniwa. Takie niewielkie uszkodzenia mogą przyjmować różną formę, np. wtargnięcie wody, która gromadzi się w pakiecie akumulatorowym, np. w skutek uszkodzonego wymiennika ciepła, i może powodować korozję oraz zwarcia w obszarach o wysokim napięciu. Właściwe projektowanie układów BMS i BTMS jest więc kluczowe dla zapewnienia bezpieczeństwa i trwałości systemu, zwłaszcza w kontekście pakietów akumulatorowych o wysokich wymogach dotyczących natężenia prądu ładowania i rozładowania. W celu wykrywania obecności wody, aktualnie stosowane są głównie elektryczne czujniki konduktometryczne i pojemnościowe (w zależności od zastosowanego BTMS), które wykazują pewne wady ze względu na stosowanie niskonapięciowych sygnałów elektrycznych w obszarach wysokonapięciowych.

Wychodząc na przeciw powyższym wyzwaniom niniejsza praca doktorska skupia się na opracowaniu systemu wykrywania nieszczelności dla samochodowych pakietów akumulatorowych z chłodzeniem zanurzeniowym. Ze względu na specyfikę chłodzenia zanurzeniowego, nieszczelność jest rozumiana w znaczeniu wycieku czynnika chłodzącego oraz wtargnięcia wody. W pracy wykorzystano tor optyczny w miejscach wysokonapięciowych, niwelując wady takie jak ekspozycja niskonapięciowych układów na wyładowania elektrostatyczne oraz zakłócenia elektromagnetyczne.

Zaprojektowanie i wykonanie prototypu takiego systemu wymagało obszernych, interdyscyplinarnych prac badawczo-rozwojowych, ze względu na konieczność opracowania dedykowanej warstwy mechanicznej, sprzętowej, programowej oraz czujników światłowodowych. Prace te doprowadziły do wytworzenia polimerowego światłowodowego czujnika absorpcji fali zanikającej oraz opracowania dedykowanej platformy sprzętowej służącej do rejestrowania danych w warunkach laboratoryjnych oraz drogowych dla systemu w stanie pełnej zdatności oraz przy celowo wprowadzonych uszkodzeniach (wyciek oleju, wtargnięcie wody). Na podstawie zgromadzonych danych przeprowadzono ich analizę, której wynikiem było sformułowanie zestawu metod detekcji uszkodzeń opartych na modelu (z sieciami LSTM, RAE-GRU), a następnie ich weryfikacja. Działanie metod było ocenianie na podstawie zarejestrowanych zestawów danych w stanie bezawaryjnym i podczas zasymulowanych stanów awaryjnych za pomocą konkretnych wskaźników wydajności modelu, jak również wskaźników wydajności detekcji.

Wyniki rozprawy doktorskiej stanowią istotny wkład w bezpieczeństwo i niezawodność litowo-jonowych pakietów akumulatorowych pojazdów elektrycznych. System optycznego wykrywania cieczy, w połączeniu z opracowanymi metodami detekcji uszkodzeń opartymi na modelach, zmniejsza ryzyka związane z wtargnięciem cieczy lub wyciekiem czynnika chłodzącego, przyczyniając się do poprawy bezpieczeństwa i spełnienia przyszłych regulacji dotyczących pojazdów elektrycznych, w szczególności regulacji dotyczących zjawiska utraty stabilności termicznej.

Z perspektywy projektu wdrożeniowego wynikiem rozprawy doktorskiej są m.in. demonstrator technologii na poziomie TRL6 oraz dwa wynalazki, których pomysłodawcą jest autor rozprawy. Wnioski patentowe mające na celu ochronę tych wynalazków zgłoszone zostały przez firmę

DRÄXLMAIER. Pierwsze zgłoszenie patentowe pt. „Optical liquid detection sensor device” zostało zarejestrowane 10 grudnia 2020 roku w Biurze Własności Intelektualnej (IPO) w Wielkiej Brytanii pod numerem GB2019513.7 [47]. Zgłoszenie zostało opublikowane pod numerem GB2602001. Drugi wniosek na wynalazek pt. „Optical liquid detection system” został zgłoszony 9 marca 2022 roku Biurze Własności Intelektualnej (IPO) w Wielkiej Brytanii pod numerem GB2203308.8 [48]. W styczniu 2023 roku komitet patentowy firmy DRÄXLMAIER zdecydował o zgłoszeniu tego wynalazku w trybie PCT.

Badania opisane w rozprawie współfinansowano w ramach Programu MNiSW „Doktorat wdrożeniowy” Nr DWD/33/33/2019. Poniżej scharakteryzowano krótko strukturę rozprawy.

Rozdział 1 przedstawia podstawy teoretyczne związane z rozprawą, podkreślając wzrost rynku elektromobilności na Świecie w ciągu ostatnich 12 lat. Rozdział opisuje motywację stojącą za badaniami wraz ze znaczeniem poruszonych kwestii, takich jak uszkodzenia pakietów akumulatorowych w pojazdach elektrycznych. Ponadto, rozdział przedstawia sformułowane problemy badawcze, wyznaczając kontekst i kierunek dla kolejnych rozdziałów.

Rozdział 2 opisuje koncepcję pakietów akumulatorowych w kontekście pojazdów elektrycznych. Rozpoczyna się od pełnego przeglądu, omawiając zalety i wady różnych chemii i kształtów ogniw dla przemysłu motoryzacyjnego. Następnie przedstawiony jest opis różnych systemów zarządzania ciepłego baterii, prowadzący czytelnika do techniki chłodzenia, istotnego dla rozprawy. Rozdział prezentuje ograniczenia ogniw litowo-jonowych, które są obecnie najpopularniejszym wyborem dla producentów samochodów. Na tej podstawie przedstawione są wyniki badań nad uszkodzeniami związanymi z pakietami akumulatorowymi, w szczególności uszkodzeniami związanymi z wyciekiem oraz wtargnięciem cieczy. Przedstawiono również wyniki przeglądu w zakresie algorytmów diagnostycznych stosowanych przez systemy baterijne, w szczególności wykorzystujących techniki sztucznej inteligencji i uczenia maszynowego. Rozdział kończy się przeglądem baz patentowych w zakresie rozwiązań służących do wykrywania wycieków oraz wtargnięcia cieczy przez pakiety akumulatorowe.

Rozdział 3 opisuje podstawowe zasady technik pomiarowych wykorzystywanych przez polimerowe czujniki światłowodowe, skupiając się na technikach bazujących na intensywności i długości fali, potencjalnie odpowiednich dla przemysłu motoryzacyjnego. W celu rozróżnienia typu płynu, badania skupiają się na czujnikach współczynnika refrakcji i rozważają ich techniki wytwarzania. Ponadto, rozdział przedstawia wyniki przeglądu w zakresie wykorzystania polimerowych czujników światłowodowych w przemyśle motoryzacyjnym, gdzie zidentyfikowano rozwiązania takie jak system ochrony pieszych oraz system detekcji przeszkody szyb elektrycznych. Ze względu na ograniczoną liczbę zastosowań znalezionych dla branży motoryzacyjnych, badania zostały rozszerzone o bardziej wymagający przemysł lotniczy.

Rozdział 4 wprowadza koncepcję optycznego systemu wykrywania cieczy w kontekście pakietów akumulatorowych samochodów elektrycznych. Dostarcza nie tylko teoretycznych podstaw w zakresie architektury i wymagań (funkcjonalnych i nefunkcjonalnych), ale także opisuje proces implementacji systemu i badania eksperymentalne dotyczące wykonanych czujników współczynnika refrakcji. Opisany proces implementacji obejmuje również projekt i wykonanie elektronicznej jednostki sterującej i protokołu komunikacji oraz skompletowany system. Badania eksperymentalne dotyczące czujników światłowodowych przedstawiają wpływ wykorzystanej procedury wytwarzania, powierzchni cięcia światłowodu, intensywności światła nadajników światłowodowych oraz temperatury na uzyskaną charakterystykę oraz czułość.

Rozdział 5 przedstawia teoretyczne podstawy autorskich metod detekcji uszkodzeń, które proponuje się do wykorzystania w optycznym systemie wykrywania cieczy. Rozdział ten zagłębia się

w rekurencyjne sieci neuronowe, ze szczególnym uwzględnieniem sieci typu Long Short-Term Memory, Gated Recurrent Units i Recurrent Autoencoders. Przedstawia opracowane techniki oparte na LSTM i RAE GRU oraz wymienia szereg wskaźników wydajności modelu, które zostały wykorzystane do oceny skuteczności modeli. Opisuje zaproponowane metody detekcji oparte o sieci LSTM oraz RAE GRU i wymienia szereg wskaźników wydajności modelu, które zostały wykorzystane do oceny skuteczności modeli. Rozdział przedstawia również wskaźniki jakości i złożoności modelu obiektu oraz zestaw wskaźników skuteczności metod detekcji.

Rozdział 6 przedstawia przeprowadzone badania weryfikacyjne opracowanego systemu detekcji nieszczelności, które zostały podzielone zgodnie z zaproponowanym planem badań na badania w warunkach laboratoryjnych oraz badania w warunkach drogowych. Pierwsza część badań skupia się ocenie skuteczności systemu i zaproponowanej metody detekcji uszkodzeń bazujących na sieciach neuronowych LSTM w warunkach laboratoryjnych. Druga część badań wykorzystuje finalną platformę mechatroniczną oraz metodę detekcji uszkodzeń wykorzystującą sieci typu autoenkoder. Szczegółowo opisano poszczególne fazy badań weryfikacyjnych, takie jak przygotowanie stanowiska badawczego, proces akwizycji danych, implementację wybranych metod oraz ocenę ich działania. Proponowane metody zostały przetestowane w trybie offline przy użyciu wcześniej zarejestrowanych zestawów danych w odpowiadającym im warunkom środowiskowym.

Ostatni rozdział pracy podsumowuje wyniki badań, prezentując dogłębną analizę najważniejszych osiągnięć oraz główne wnioski. Ponadto, zaproponowano potencjalne kierunki przyszłych prac, uwypuklając interdyscyplinarność podjętej tematyki. Podsumowano również osiągnięte kamienie milowe oraz opisano wybrane etapy wdrożenia do przemysłu.

Literatura

[1] International Energy Agency, "Global EV outlook 2023," tech. rep., International Energy Agency, Paris, France, 2023.

[2] W. Chao, Z. Chunbo, G. Yunwang, and Z. Yongping, "A review on fault mechanism and diagnosis approach for Li-Ion batteries," *Journal of Nanomaterials*, vol. 15, 2015.

[3] Sony, "Lithium-Ion rechargeable battery technical information -US18650VTC6," 2015. Rev. 0.2.

[4] M.-K. Tran and M. Fowler, "A review of Lithium-Ion battery fault diagnostic algorithms: Current progress and future challenges," *Algorithms*, vol. 13, no. 3, 2020.

[5] C. Roe, X. Feng, G. White, R. Li, H. Wang, X. Rui, C. Li, F. Zhang, V. Null, M. Parkes, Y. Patel, Y. Wang, H. Wang, M. Ouyang, G. Offer, and B. Wu, "Immersion cooling for Lithium-Ion batteries – a review," *Journal of Power Sources*, vol. 525, p. 231094, 03 2022.

[6] Y. Miao, P. Hynan, A. Von Jouanne, and A. Yokochi, "Current Li-Ion battery technologies in electric vehicles and opportunities for advancements," *Energies*, vol. 12, no. 6, pp. 1–20, 2019.

[7] J. Choi and D. Aurbach, "Promise and reality of post-Li-Ion batteries with high Energy densities," *Nature Reviews Materials*, vol. 1, 2016.

[8] M. Zwicker, M. Moghadam, W. Zhang, and C. Nielsen, "Automotive battery pack manufacturing -a review of battery to tab joining," *Journal of Advanced Joining Processes*, vol. 1, 2020.

[9] L. Lu, X. Han, L. Jianqiu, J. Hua, and M. Ouyang, "A review on the key issues for Lithium-Ion battery management in electric vehicles," *Journal of Power Sources*, vol. 226, pp. 272–288, 03 2013.

[10] Electric Vehicle Subcommittee, "Electric vehicle safety global technical regulation – protection against water," tech. rep., Japan Automobile Manufacturers Association, China, 2019.

[11] PV Magazine, "Fire at victorian big battery now under control." Accessed: 18.06.2023 <https://www.pv-magazine-australia.com/2021/08/02/fire-at-victorian-bigbattery-now-under-control/>, 2021.

- [12] Motor1, "McLaren reveals speedtail electric secrets." Accessed: 08.01.2022 <https://uk.motor1.com/news/419393/mclaren-reveals-speedtail-electric-secrets/>, 2020.
- [13] Mercedes-AMG, "World premiere of the first performance hybrid from mercedes-amg." Accessed: 07.01.2022 <https://www.mercedes-amg.com/en/world-of-amg/news/press-information/mercedes-amg-gt-63-s-e-performance.html>, 2022.
- [14] Porsche, "Porsche taycan." Accessed: 01.08.2023 <https://www.porsche.com/international/models/taycan/taycan-models/taycan/>, 2023.
- [15] A. Samanta, S. Chowdhuri, and S. Williamson, "Machine learning-based data-driven fault detection/diagnosis of Lithium-Ion battery: A critical review," *Electronics*, vol. 10, p. 1309, 05 2021.
- [16] Y. Zhao, P. Liu, Z. Wang, L. Zhang, and J. Hong, "Fault and defect diagnosis of battery for electric vehicles based on big data analysis methods," *Applied Energy*, 06 2017.
- [17] J. Hong, Z. Wang, and Y. Yao, "Fault prognosis of battery system based on accurate voltage abnormality prognosis using long short-term memory neural networks," *Applied Energy*, vol. 251, 10 2019.
- [18] Y. Li, C. Zou, M. Berecibar, E. Nanini-Maury, J. Chan, P. Van den Bossche, J. Van Mierlo, and N. Omar, "Random forest regression for online capacity estimation of Lithium-Ion batteries," *Applied Energy*, vol. 232, pp. 197–210, 09 2018.
- [19] L. Yao, Z. Fang, Y. Xiao, J.-J. Hou, and Z. Fu, "An intelligent fault diagnosis method for lithium battery systems based on grid search support vector machine," *Energy*, vol. 214, p. 118866, 01 2021.
- [20] P. Ortiz, J. Valladolid, C. Garcia, G. Novillo, and F. Berrezueta, "Analysis of machine learning techniques for the intelligent diagnosis of Ni-MH battery cells," pp. 1–6, 11 2018.
- [21] D. Yang, X. Zhang, R. Pan, Y. Wang, and Z. Chen, "A novel gaussian process regression model for state-of-health estimation of Lithium-Ion battery using charging curve," *Journal of Power Sources*, vol. 384, pp. 387–395, 04 2018.
- [22] P. Tagade, K. Hariharan, S. Ramachandran, A. Khandelwal, A. Naha, S. Kolake, and S. Han, "Deep gaussian process regression for Lithium-Ion battery health prognosis and degradation mode diagnosis," *Journal of Power Sources*, vol. 445, p. 227281, 01 2020.
- [23] M. Fasahat and M. Manthouri, "State of charge estimation of Lithium-Ion batteries using hybrid autoencoder and long short term memory neural networks," *Journal of Power Sources*, vol. 469, p. 228375, 09 2020.
- [24] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.-A. Manzagol, "Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion," *Journal of Machine Learning Research*, vol. 11, pp. 3371–3408, 12 2010.
- [25] X. Kong, Y. Zheng, M. Ouyang, L. Lu, L. Jianqiu, and Z. Zhang, "Fault diagnosis and quantitative analysis of micro-short circuits for Lithium-Ion batteries in battery packs," *Journal of Power Sources*, vol. 395, pp. 358–368, 08 2018.
- [26] B. Xia, Y. Shang, T. Nguyen, and C. Mi, "A correlation based fault detection method for short circuits in battery packs," *Journal of Power Sources*, vol. 337, pp. 1–10, 01 2017.
- [27] Y. Kang, B. Duan, Z. Zhou, Y. Shang, and C. Zhang, "A multi-fault diagnostic method based on an interleaved voltage measurement topology for series connected battery packs," *Journal of Power Sources*, vol. 417, pp. 132–144, 03 2019.
- [28] J. Xiong, H. Banvait, L. Li, Y. Chen, J. Xie, Y. Liu, M. Wu, and J. Chen, "Failure detection for over-discharged Li-ion batteries," 2012 IEEE International Electric Vehicle Conference, IEVC 2012, 03 2012.

- [29] V. Muddappa and S. Anwar, "Electrochemical model based fault diagnosis of Li-Ion battery using fuzzy logic," ASME International Mechanical Engineering Congress and Exposition, Proceedings (IMECE), vol. 4, 11 2014.
- [30] M. Miedreich and H. Schober, "Pedestrian protection system, featuring fiber optic sensor," ATZ Worldwide, vol. 107, no. 3, pp. 15–19, 2005.
- [31] G. Kodl, "A new optical waveguide pressure sensor using evanescent field," pp. 1943 – 1946 Vol.2, 07 2004.
- [32] P. Lallana, G. Aldabaldetrekú, A. López, D. Montero, G. Durana, J. Mateo, M. A. Losada, J. Zubia, and C. Vázquez, "Sensing applications in aircrafts using polymer optical fibres," Sensors, vol. 21, p. 3605, 05 2021.
- [33] W. Zhang, D. Webb, M. Carpenter, and C. Williams, "Measuring water activity of aviation fuel using a polymer optical fiber bragg grating," Proceedings of SPIE - The International Society for Optical Engineering, vol. 9157, 06 2014.
- [34] G. Durana, M. Kirchhof, M. Lubert, I. Ocáriz, H. Poisel, J. Zubia, and C. Vázquez, "Use of a novel fiber optical strain sensor for monitoring the vertical deflection of an aircraft flap," IEEE Sensors Journal, vol. 9, 11 2009.
- [35] O. Ziemann, J. Krauser, P. E. Zamzow, and W. Daum, POF Handbook. Berlin: Springer, 2008.
- [36] A. Sharma, J. Gupta, and S. Ishika, "Fiber optic evanescent wave absorption-based sensors: A detailed review of advancements in the last decade (2007-18)," Optik, vol. 183, 02 2019.
- [37] FBGS International, "Website." Accessed: 30.07.2021 <https://fbgs.com/>, 2021.
- [38] A. Onoufriou, K. Kalli, and G. Kohnke, "Fiber bragg gratings: Fundamentals and applications in telecommunications and sensing," Physics Today - PHYS TODAY, vol. 53, 05 2000.
- [39] D. Webb, "Fibre bragg grating sensors in polymer optical fibres," Measurement Science and Technology, vol. 26, 09 2015.
- [40] S. Wang, D. Zhang, Y. Xu, S. Sun, and X. Sun, "Refractive index sensor based on double side-polished U-shaped plastic optical fiber," Sensors, vol. 20, p. 5253, 09 2020.
- [41] J. Shin and P. Jaehee, "Plastic optical fiber refractive index sensor employing an in-line submillimeter hole," Photonics Technology Letters, IEEE, vol. 25, pp. 1882–1884, 10 2013.
- [42] F. De-Jun, L. Guan-Xiu, L. Xi-Lu, J. Ming-Shun, and S. Qing-Mei, "Refractive index sensor based on plastic optical fiber with tapered structure," Applied optics, vol. 53, pp. 2007–2011, 04 2014.
- [43] F. Sequeira, N. Cennamo, A. Rudnitskaya, R. Nogueira, L. Zeni, and L. Bilro, "D-shaped POF sensors for refractive index sensing-the importance of surface roughness," Sensors, vol. 19, p. 2476, 05 2019.
- [44] L. Bilro, N. Alberto, J. Pinto, and R. Nogueira, "Optical sensors based on plastic fibers," Sensors (Basel, Switzerland), vol. 12, pp. 12184–207, 12 2012.
- [45] G. Wójcik and P. Przystałka, "Experimental investigation of factors influencing the transmission capabilities of a low cost, side-polished evanescent wave absorption plastic optical fiber sensors," Procedia Structural Integrity, vol. 37, pp. 179–186, 02 2022.
- [46] G. Wójcik and P. Przystałka., „LSTM Model-Based Fault Detection for Electric Vehicle’s Battery Packs,” Lecture Notes in Networks and Systems, vol 545, 2022.
- [47] G. Wójcik, "Optical liquid detection sensor device," U.K. Patent GB2602001A, 01 2021.
- [48] G. Wójcik, "Optical liquid detection system," U.K. Patent GB2203308, 03 2022.