

POLITECHNIKA POZNAŃSKA
WYDZIAŁ AUTOMATYKI, ROBOTYKI I ELEKTROTECHNIKI



Tytuł rozprawy doktorskiej

***Modeling the degradation process of lithium-ion cells
taking into account dynamically variable load***

***Modelowanie procesu zużycia ogniw litowo-jonowych
z uwzględnieniem dynamicznie zmiennego obciążenia***

mgr inż. Damian Burzyński

Dziedzina: nauki inżynieryjno-techniczne

Dyscyplina naukowa: automatyka, elektronika i elektrotechnika

Promotor: dr hab. inż. Leszek Kasprzyk, profesor uczelni

Poznań, 2022

Spis treści

Streszczenie	3
1. Wykształcenie	5
2. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych	6
3. Rozprawa doktorska	7
3.1. Tytuł rozprawy doktorskiej	7
3.2. Cel rozprawy doktorskiej	7
3.3. Wykaz powiązanych tematycznie publikacji wchodzących w skład rozprawy	7
3.4. Omówienie problemu naukowego oraz opis publikacji wchodzących w skład rozprawy doktorskiej	8
3.4.1. Wprowadzenie i uzasadnienie wyboru podjętej tematyki	8
3.4.2. Modelowanie procesu zużycia ogniwo litowo-jonowych	9
3.4.3. Badania eksperymentalne	10
3.4.4. Omówienie uzyskanych wyników	13
3.4.5. Podsumowanie	33
4. Podsumowanie działalności naukowo-badawczej	35
4.1. Podsumowanie dotychczasowego dorobku publikacyjnego	35
4.2. Pozostałe osiągnięcia naukowo-badawcze	36
4.3. Pozostała aktywność naukowa	40
5. Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę	42
6. Inne informacje ważne z punktu widzenia kariery zawodowej	43
Wykaz literatury	44
Załącznik 1. Wartości dobranych parametrów pracy cyklicznej	48
Załącznik 2. Weryfikacja modelu – porównanie odpowiedzi modelu z wartościami eksperymentalnymi dla danych uczących	49
Załącznik 3. Wartości parametrów pracy cyklicznej oraz wyniki wstępnych obliczeń	50
Załącznik 4. Dane dotyczące cytowalności poszczególnych artykułów naukowych w wybranych bazach naukowych	51

Streszczenie

Niniejsza rozprawa doktorska pt. „Modelowanie procesu zużycia ogniw litowo-jonowych z uwzględnieniem dynamicznie zmiennego obciążenia” złożona jest w formie monotematycznego cyklu oryginalnych artykułów naukowych składającego się z trzech publikacji. W rozprawie przedstawiono nowe metody modelowania procesu zużycia ogniw typu NMC 18650 z wykorzystaniem systemów mających zdolność uogólniania wiedzy, takich jak logika rozmyta oraz metod uczenia maszynowego z nadzorem. W pracy Burzyński D., Pietracho R., Kasprzyk L., Tomczewski A., „*Analysis and Modeling of the Wear-Out Process of a Lithium-Nickel-Manganese-Cobalt Cell during Cycling Operation under Constant Load Conditions*” badano wpływ wybranych parametrów pracy na liczbę cykli, które może wykonać ogniwo zanim osiągnie założony wskaźnik zużycia. Na podstawie przeprowadzonych analiz i uzyskanych wyników zaproponowano nowy typ funkcji odwzorowującej wpływ temperatury otoczenia na liczbę cykli pracy ogniwa. Przedstawiono koncepcję modelu rozmytego typu Mamdaniego umożliwiającego wyznaczenie stanu zużycia ogniwa. W artykule Burzyński D., Kasprzyk L., „*A novel method for the modeling of the state of health of lithium-ion cells using machine learning for practical applications*” opisano wyniki badań trwałości ogniw prowadzonych w dwóch aspektach. Pierwszy dotyczył badania i analizy wpływu poszczególnych parametrów pracy cyklicznej na szybkość zużycia ogniwa w stałych warunkach obciążeniowych. Wykazano, iż proces zużycia ogniw charakteryzuje się wysoką zmiennością w zależności od wartości parametrów pracy cyklicznej (przede wszystkim dotychczasowego stanu zużycia ogniwa). Na podstawie szczegółowych analiz opracowano autorski, wieloparametryczny model predykcji szybkości zużycia ogniwa, uwzględniający jego dotychczasowe zużycie. Drugi aspekt związany był z weryfikacją modelu podczas dynamicznie zmiennego obciążenia (generowanego w sposób losowy), w założonym okresie eksploatacji. Wykazano wysoką skuteczność zaproponowanego modelu. W publikacji Burzyński D., „*Useful Energy Prediction Model of a Lithium-ion Cell Operating at Various Duty Cycles*” zajęto się zagadnieniem predykcji relatywnej energii użytecznej (RUE_c), którą ogniwo może wymienić w trakcie pełnego cyklu pracy, podczas całego okresu eksploatacji. Skutkiem przeprowadzonych analiz była między innymi identyfikacja trzech wzorców dynamiki zmian dostępnej energii dla ogniw pracujących w różnych warunkach obciążeniowych i temperaturowych. Opracowano nowy model uczenia maszynowego z nadzorem, umożliwiający predykcję relatywnej energii użytecznej, a następnie udowodniono jego wysoką dokładność. W celu wyznaczenia istotności poszczególnych parametrów modelu oraz ich ilościowego wpływu na uzyskane wyniki, zastosowano techniki wyjaśnialnego uczenia maszynowego (metodę istotności zmiennych oraz zakumulowanych efektów lokalnych pierwszego i drugiego rzędu). We wszystkich wymienionych artykułach szczegółowo opisano procedurę eksperymentalną oraz proponowane oryginalne metody modelowania, wykorzystujące wyniki przeprowadzonych przez autora badań i analiz naukowych, a także udowodniono ich skuteczność.

Do rozprawy doktorskiej dołączono autoreferat składający się z sześć rozdziałów. W rozdziale 1 i 2 przedstawiono wykształcenie doktoranta oraz informacje o jego dotychczasowym zatrudnieniu w jednostkach naukowych. W rozdziale 3 zawarto szczegółowy opis artykułów naukowych wchodzących w skład rozprawy doktorskiej. Podsumowanie całej działalności naukowo-badawczej wraz z informacjami o cytowalności publikacji Autora zawarto w rozdziale 4. W rozdziale 5 przedstawiono działalność dydaktyczną doktoranta. Pozostałe informacje istotne z punktu widzenia kariery naukowej doktoranta przedstawiono w rozdziale 6.

Abstract

This dissertation entitled „Modeling the degradation process of lithium-ion cells, taking into account dynamically variable load” is submitted as a monothematic series of original scientific articles consisting of three publications. This thesis presents new techniques for modeling the degradation process of 18650 NMC cells using methods that have knowledge generalization ability, such as fuzzy logic and supervised machine learning methods. In the paper [Burzyński D.](#), Pietracho R., Kasprzyk L., Tomczewski A., „*Analysis and Modeling of the Wear-Out Process of a Lithium-Nickel-Manganese-Cobalt Cell during Cycling Operation under Constant Load Conditions*” the effect of selected operating parameters on the number of cycles a cell can complete before it reaches its degradation rate was studied. On the basis of conducted analyses and obtained results, a new type of function mapping the ambient temperature influence on the number of cell operating cycles was proposed. The concept of fuzzy model of Mamdani type enabling determination of cell state of health was presented. The article [Burzyński D.](#), Kasprzyk L., „*A novel method for the modeling of the state of health of lithium-ion cells using machine learning for practical applications*” describes the result of cell life studies conducted in two aspects. The first concerned the study and analysis of the influence of individual parameters of cyclic operation on the rate of cell degradation under constant load conditions. It was shown that the process of cell degradation is characterized by high variability depending on the value of parameters of cyclic operation (cell actual state of health). On the basis of detailed analyses an authorial, multi-parametric model of cell degradation rate prediction was developed, taking into account its actual state of health. The second aspect was connected with verification of the model during dynamically varying load (randomly generated), in the assumed operation period. High efficiency of the proposed model was demonstrated. The paper [Burzyński D.](#), „*Useful Energy Prediction Model of a Lithium-ion Cell Operating at Various Duty Cycles*” addresses the issue of predicting the relative useful energy (RUE_c) that cell can transfer during a full duty cycle, over its lifetime. The analyses resulted, among other things, in the identification of three patterns of dynamics of changes in available useful energy for cells operating under different load and temperature conditions. A new supervised machine learning model for the prediction of relative useful energy was developed and its high accuracy was proven. Explainable machine learning techniques (variable importance method and first- and second-order accumulated local effects) were used to determine the significance of individual model parameters and their quantitative impact on the results obtained. In all the mentioned articles, the experimental procedure and the proposed original modeling methods are described in detail, using the results of the author’s scientific research and analysis, and their effectiveness is proven.

The dissertation is accompanied by an autoreference consisting of six chapters. Chapters 1 and 2 present the doctoral student’s educational background and information about his previous employment in scientific institutions. Chapter 3 contains a detailed description of the scientific articles included in the dissertation. The summary of the whole scientific and research activity together with the information about citation rate of the author’s publications is contained in Chapter 4. Chapter 5 presents the didactic activity of the doctoral student. Other information relevant to the scientific career of the doctoral student is presented in Chapter 6.

1. Wykształcenie

- Tytuł zawodowy: Magister inżynier
Uczelnia: Politechnika Poznańska
Wydział: Wydział Elektryczny
Kierunek: *Elektrotechnika*
Specjalność: *Układy i instalacje elektryczne*
Rok ukończenia: 2015

- Tytuł zawodowy: Inżynier
Uczelnia: Politechnika Poznańska
Wydział: Wydział Elektryczny
Kierunek: *Energetyka*
Specjalność: *Ekologiczne źródła energii elektrycznej*
Rok ukończenia: 2011

2. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych

- Od 01.10.2015 do 25.11.2018 – asystent w Instytucie Elektrotechniki i Elektroniki Przemysłowej na Wydziale Elektrycznym Politechniki Poznańskiej.
- Od 26.11.2018 do 29.02.2020 – wykładowca w Instytucie Elektrotechniki i Elektroniki Przemysłowej na Wydziale Automatyki, Robotyki i Elektrotechniki Politechniki Poznańskiej.
- Od 01.03.2020 do 30.11.2021 – asystent (grupa dydaktyczna) w Instytucie Elektrotechniki i Elektroniki Przemysłowej na Wydziale Automatyki, Robotyki i Elektrotechniki Politechniki Poznańskiej.
- Od 01.12.2021 – asystent (grupa badawcza) w Instytucie Elektrotechniki i Elektroniki Przemysłowej na Wydziale Automatyki, Robotyki i Elektrotechniki Politechniki Poznańskiej.

3. Rozprawa doktorska

3.1. Tytuł rozprawy doktorskiej

Modelowanie procesu zużycia ogniw litowo-jonowych z uwzględnieniem dynamicznie zmiennego obciążenia.

3.2. Cel rozprawy doktorskiej

Celem rozprawy doktorskiej jest opracowanie nowych, efektywnych metod wyznaczania parametrów wykorzystywanych do określania zużycia ogniw litowo-jonowych w warunkach dynamicznie zmiennego obciążenia. Opracowane metody, uwzględniając dodatkowo ich dotychczasowe zużycie, mają umożliwić wyznaczenie stopnia zużycia ogniw z dokładnością większą niż stosowane obecnie.

3.3. Wykaz powiązanych tematycznie publikacji wchodzących w skład rozprawy doktorskiej

[DB-1] Burzyński D., Pietracho R., Kasprzyk L., Tomczewski A., „*Analysis and Modeling of the Wear-Out Process of a Lithium-Nickel-Manganese-Cobalt Cell during Cycling Operation under Constant Load Conditions*”, *Energies* 2019, 12(20), 3899

(140 pkt. *MNiSW*; *IF* = 2,702).

Udział procentowy:

<u>Burzyński D.</u>	64%
Pietracho R.	16%
Kasprzyk L.	12%
Tomczewski A.	8%

[DB-2] Burzyński D., Kasprzyk L., „*A novel method for the modeling of the state of health of lithium-ion cells using machine learning for practical applications*”, *Knowledge-Based Systems* 219, 11 May 2021, 106900.

(200 pkt. *MEiN*; *IF* = 8,038).

Udział procentowy:

Burzyński D.	90%
Kasprzyk L.	10%

[DB-3] Burzyński D., „*Useful energy prediction model of a Lithium-ion cell operating at various duty cycles*”, *Eksploracja i Niezawodność – Maintenance and Reliability* 2022, 24 (2): 317-328

(140 pkt. *MEiN*; *IF* = 2,176).

3.4. Omówienie problemu naukowego oraz opis publikacji wchodzących w skład rozprawy doktorskiej

3.4.1. Wprowadzenie i uzasadnienie wyboru podjętej tematyki

Jednym z celów europejskiej polityki klimatycznej do roku 2030 jest ograniczenie emisji gazów cieplarnianych o co najmniej 40% w stosunku do roku 1990. Według Europejskiej Agencji Środowiska jednym z największych źródeł emisji gazów cieplarnianych do atmosfery jest sektor gospodarki związany z transportem [1]. Jest on odpowiedzialny za ponad 25% emisji na obszarze krajów należących do Unii Europejskiej. Znaczna część tych gazów – około 70% – pochodzi z transportu samochodowego. Aby ograniczyć ich emisję producenci pojazdów osobowych, ciężarowych, a nawet środków transportu indywidualnego, w ostatnich kilkunastu latach inwestują oraz wdrażają elektryczne układy napędowe, które najczęściej zasilane są przez pakiety ogniw elektrochemicznych. Akumulatory elektrochemiczne mają także szerokie zastosowania w przemyśle energetycznym jako stacjonarne magazyny energii. Są one również najczęściej stosowanym magazynem energii współpracującym z systemami wytwarzającymi energię ze źródeł odnawialnych. Co więcej, obecne pakiety złożone z ogniw litowo-jonowych są powszechnie stosowane do zasilania mobilnych urządzeń elektronicznych codziennego użytku [2].

Pierwszym wtórnym ogniwem elektrochemicznym był akumulator kwasowo-ołowiowy (wynaleziony już ponad 150 lat temu), jednak na przestrzeni ostatnich lat zauważyć można stopniowe ich wypieranie przez ogniwa litowo-jonowe, które cechują się lepszymi parametrami użytkowymi. Obecnie pojawia się wiele technologii akumulatorów litowych, których charakterystyka pracy i ograniczenia eksploatacyjne różnią się od siebie (różne gęstości energii, mocy oraz trwałość, zakres dopuszczalnych prądów, napięć i temperatur pracy) [3]. Niezachowanie warunków eksploatacyjnych prowadzi do spadku trwałości, a w skrajnych sytuacjach może spowodować nawet pożar. Dlatego coraz ważniejsza staje się analiza (nadzorowanie) ich funkcjonowania oraz modelowanie pracy i predykcja trwałości. Należy podkreślić, że w przypadku systemów zasilanych z ogniw litowo-jonowych, np. pojazdów elektrycznych, koszt akumulatorów stanowi niemal połowę nakładów inwestycyjnych, co sprawia, że ich trwałość jest jednym z najważniejszych aspektów projektowania i zarządzania pracą.

Z tego powodu Autor w 2015 roku rozpoczął badania nad zagadnieniem modelowania ogniw elektrochemicznych. Wyniki pierwszych analiz Autor przedstawił w pracach [DB-6 – DB-10, DB-14, DB-16 – DB-20]. Prowadzone wówczas badania oraz analiza obecnego stanu wiedzy wykazała, że dotychczas nie opracowano wystarczająco dokładnych modeli umożliwiających przewidywanie procesu zużycia ogniw w całym okresie ich eksploatacji, szczególnie podczas dynamicznie zmiennego obciążenia [4–9]. W wielu pracach przedstawiane jest podejście uproszczone, a proponowane modele procesu zużycia nie uwzględniają istotnych parametrów pracy cyklicznej lub wpływ tych parametrów jest uwzględniony w wąskim zakresie zmienności [7,10–14]. Są to główne powody, dla których opracowanie nowych, efektywnych modeli, umożliwiających przewidywanie stopnia zużycia akumulatorów w różnych warunkach eksploatacyjnych jest obecnie bardzo istotne i często podejmowane w wielu ośrodkach badawczych na całym świecie [15–20]. Zagadnienie to stanowi ważny i nierozwiązany problem naukowy.

W związku z występowaniem luki wiedzy w zakresie metod modelowania trwałości ogniw, celem rozprawy doktorskiej jest opracowanie nowych, efektywnych metod wyznaczania parametrów wykorzystywanych do określania zużycia ogniw litowo-jonowych w warunkach dynamicznie zmiennego obciążenia. Opracowane metody, uwzględniając dodatkowo ich dotychczasowe zużycie, mają umożliwić wyznaczenie stopnia zużycia ogniw z dokładnością większą niż stosowane obecnie.

Przedstawiony cykl monotematycznych publikacji obejmuje podjętą tematykę, a wykonane przez Autora badania eksperymentalne, analizy oraz opracowane oryginalne metody modelowania doprowadziły do rozwiązania opisanego problemu naukowego.

3.4.2. Modelowanie procesu zużycia ogniw litowo-jonowych

Degradacja ogniw litowo-jonowych jest niezwykle złożonym zagadnieniem, wynikającym ze zjawisk starzeniowych zachodzących w całym obszarze ogniwa: na katodzie, anodzie, w obszarze styku elektrod z elektrolitem, w elektrolicie oraz separatorze. Jednak w światowej literaturze naukowej udowodniono, że decydujący wpływ na proces zużycia ogniw mają zjawiska elektrochemiczne zachodzące w obszarze elektrod oraz w warstwie ich styku z elektrolitem [21–25]. Są to zjawiska polegające na wzroście i ewolucji warstwy pasywnej, osadzaniu się cząstek metalu oraz korozji elektrod. Prowadzą one do utraty masy czynnej elektrod i w konsekwencji do destabilizacji procesów interkalacji i deinterkalacji jonów litu [26]. Spośród innych zjawisk, mogących mieć wpływ na proces zużycia, należy wymienić takie zjawiska jak rozkład elektrolitu, plastycznego odkształcenia separatora oraz gazowania cząstek. Zjawiska starzeniowe obejmują ogniwa zarówno w stanie bezobciążeniowym (tzw. zużycie kalendarzowe), jak i podczas pracy cyklicznej (półcykli ładowania i rozładowania). Szybkość tych zjawisk jest zależna od parametrów półcykli pracy ogniwa. Skutkuje to wzrostem rezystancji wewnętrznej oraz zmniejszeniem pojemności ogniwa, co w rezultacie prowadzi do utraty zdolności ogniwa do gromadzenia i oddawania ładunku, a w konsekwencji ograniczenia gęstości mocy i energii.

Stan zużycia ogniw elektrochemicznych wyrażany jest za pomocą parametru *SOH* (ang. State of Health), który jest wskaźnikiem określającym aktualną pojemność ogniwa w porównaniu z pojemnością nowego ogniwa (zależność 1). Zależność ta była wykorzystana we wszystkich pracach wchodzących w skład rozprawy doktorskiej.

$$SOH = \frac{C_{act}}{C_{new}} \cdot 100\% \quad (1)$$

gdzie: C_{act} – aktualna pojemność ogniwa, C_{new} – pojemność nowego ogniwa.

Do wyznaczenia *SOH*, zamiast pojemności, mogą być również wykorzystywane takie parametry jak: rezystancja wewnętrzna, ilość wymienionego ładunku lub energii, a także czas eksploatacji ogniwa. Dla nowych ogniw parametr *SOH* wynosi 100%, natomiast wartość *SOH*, po osiągnięciu której ogniwo jest uznawane za zużyte, zależy od obszaru zastosowania, lecz najczęściej przyjmuje się 80% [27–31].

W zagadnieniach związanych z modelowaniem procesu zużycia ogniw w stanach dynamicznie zmiennego obciążenia należy uwzględnić parametry ogniwa w czasie ładowania oraz rozładowania, do których zalicza się przede wszystkim: temperaturę otoczenia lub temperaturę ogniwa, prąd ładowania i rozładowania, napięcie ogniwa lub głębokość rozładowania, średni stan naładowania oraz aktualny stan zużycia ogniwa [32–33]. Analizowana jest zmienność dostępnej mocy, energii i pojemności w funkcji liczby wykonanych cykli pracy

lub ilości wymienionego ładunku. Należy także podkreślić, że niektóre parametry pracy cyklicznej są ze sobą skorelowane i charakteryzują się nieliniowym i trudnym do identyfikacji wpływem na zużycie ogniw. Z tego powodu największą trudnością w modelowaniu procesu zużycia jest badanie ogniw w sposób umożliwiający selektywną analizę wpływu parametrów pracy na trwałość oraz predykcja punktów przegięć, po których następuje przyspieszenie lub zwolnienie procesu zużycia ogniw [33–34].

Na przestrzeni ostatnich kilkudziesięciu lat rozwinięto wiele metod modelowania procesu zużycia ogniw litowo-jonowych. Spośród nich wyróżnić można dwa podejścia: fizykochemiczne oraz empiryczne. Modele fizykochemiczne polegają na opisie wpływu wybranych parametrów na procesy starzeniowe za pomocą zależności fizycznych i chemicznych. Umożliwiają one stosunkowo dokładne wyznaczenie przebiegu zjawisk elektrochemicznych prowadzących do degradacji w każdej części ogniwa (modele dwuwymiarowe i trójwymiarowe), jednak identyfikacja ich parametrów jest bardzo złożona i wymagają one zaawansowanych metod obliczeniowych [33,35–37]. Z tego powodu są one czasochłonne i rzadko stosowane. Natomiast metody empiryczne polegają na wyznaczaniu parametrów ogniw na podstawie danych uzyskanych z procedur eksperymentalnych, bez konieczności analizy złożonych procesów elektrochemicznych. W rezultacie są one częściej stosowane w zastosowaniach inżynierskich.

Spośród technik modelowania stanu zużycia ogniw, należących do grupy empirycznych, wyróżnić można podejście multiplikatywne. W tych modelach na podstawie wykonanych badań doświadczalnych określany jest typ funkcji odwzorowującej wpływ poszczególnych parametrów pracy cyklicznej (przy zachowaniu stałych wartości pozostałych parametrów) na *SOH* ogniwa [4,16,19,38–39]. Przykładem takiego modelu jest funkcja opisana ogólnym równaniem:

$$SOH(T, I_d, I_{ch}, DOD) = f(T) \cdot f(I_d) \cdot f(I_{ch}) \cdot f(DOD) \quad (2)$$

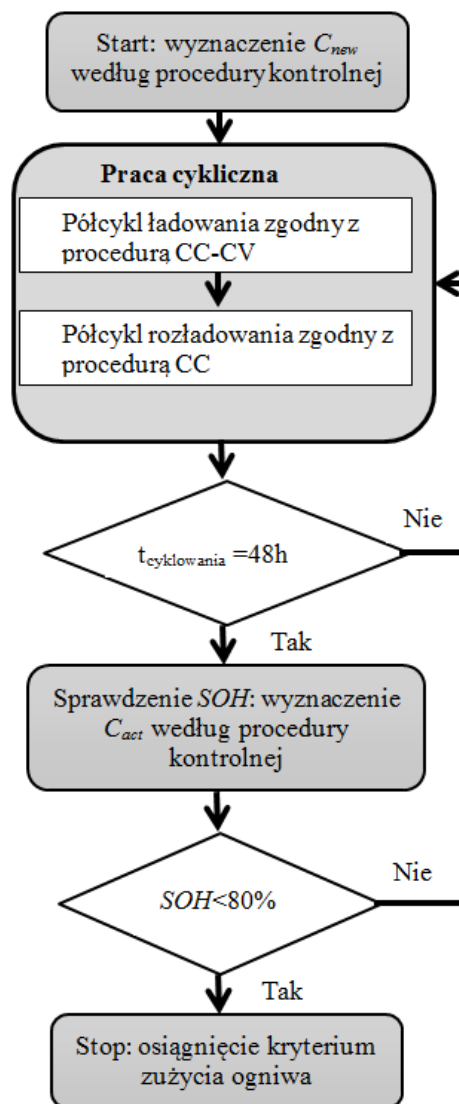
gdzie: $f(T)$ – funkcja opisująca wpływ temperatury, $f(I_d)$ – funkcja opisująca wpływ prądu rozładowania, $f(I_{ch})$ – funkcja opisująca wpływ prądu ładowania, $f(DoD)$ – funkcja opisująca wpływ głębokości rozładowania.

Kolejnymi empirycznymi metodami modelowania procesu zużycia ogniw litowo-jonowych podczas ich eksploatacji są metody uogólniające wiedzę. Do grupy tej zalicza się takie metody jak np. sieci neuronowe, systemy rozmyte, systemy szare, sieci bayesowskie, metody uczenia maszynowego, metody głębokiego uczenia, a także bazujące na nich metody hybrydowe [34,40–57]. Główną zaletą powyższych technik w porównaniu z modelami fizykochemicznymi jest brak konieczności analizowania złożonych zjawisk elektrochemicznych oraz szybkość uzyskiwania wyników (otrzymywana po fazie wstępnego uczenia modelu), co jest bardzo istotne w wielu rozwiązaniach praktycznych.

3.4.3. Badania eksperymentalne

Proces zużycia ogniw litowo-jonowych przebiega powoli (niekiedy kilka lat) i zależy od wielu parametrów. Dlatego w celu pozyskania danych związanych ze zużyciem ogniw podczas pracy cyklicznej (w różnych warunkach obciążeniowych i temperaturowych) zaplanowano i przeprowadzono wieloletnie badania, podczas których analizowano wpływ różnych parametrów na właściwości ogniw w całym okresie eksploatacji (od $SOH = 100\%$ do $SOH = 80\%$). Do badań wybrano komercyjne cylindryczne ogniwo litowo-niklowo-manganowo-kobaltowe (NMC) Samsung ICR 18650-26H (z grafitową anodą) o napięciu znamionowym równym $U_n = 3,63$ V i pojemności znamionowej równej $C_n = 2,6$ Ah. Minimalne i maksymalne napięcie ogniwa


wynosi odpowiednio 2,75 V i 4,20 V (według danych katalogowych [58]). Do realizacji badań starzeniowych opracowano algorytm postępowania zaprezentowany na rys. 1. Każde z ogniw zostało poddane pracy cyklicznej w unikalnych warunkach temperaturowych i obciążeniowych. Podczas badań do utrzymania stałej temperatury otoczenia wykorzystano komorę temperaturową Panasonic MIR-254. Zakres temperatur otoczenia w jakich badano ogniwa zawierał się w przedziale od 5°C do 40°C. Podczas testów rejestrowano chwilowe temperatury ogniw za pomocą sond Pt100 umieszczonych w centralnym punkcie ogniw. Do realizacji półcykli ładowania i rozładowania wykorzystano aparaturę dedykowaną do ogniw elektrochemicznych (Pulsar 3, Pulsar 3+ oraz Cadex C8000).



Rys. 1. Algorytm postępowania przyjęty podczas realizacji wariantów starzeniowych.

Półcykle ładowania realizowane były według standardowej procedury stały prąd – stałe napięcie (CC-CV ang. constant current – constant voltage), natomiast półcykle rozładowania stałym prądem (CC). Wartości prądów ładowania (podczas fazy CC) dobierano z zakresu od 1,3 A do 7,8 A, natomiast prądów rozładowania od 2,6 A do 10,4 A. Głębokość rozładowania (*DoD*) dobierana była z zakresu od 16% do 100%, przy założeniu, że *DoD* = 100% oznacza rozładowanie od napięcia 4,20 V (ogniwo w pełni naładowane) do 2,75 V (ogniwo rozładowane). Podczas pracy cyklicznej czas przerwy między półcyklami ładowania i rozładowania był stały i wynosił 15 s. Wartości prądów mierzone były z rozdzielczością $\pm 0,001$ A. Napięcie na zaciskach

ogniwa mierzone było za pomocą osobnych przewodów z rozdzielczością $\pm 0,001$ V, a dla pomiaru temperatury otoczenia oraz ogniwa wynosiła ona $\pm 0,1^{\circ}\text{C}$. Do akwizycji danych wykorzystano wielokanałowy rejestrator Graphtec midiLogger GL840. Widok stanowiska badawczego przedstawiono na rys. 2. Procedurę eksperymentalną poprzedziło przygotowanie stanowiska badawczego oraz planowanie eksperymentu i konfiguracja aparatury badawczej. Czynności przygotowawcze trwały 12 miesięcy. Następnie nieprzerwanie przez okres 5 lat prowadzono badania eksperymentalne, w trakcie których przebadano łącznie 104 ogniwa typu NMC. Sprawdzenie aktualnego stanu zużycia ogniw wykonywane było co dwie doby z wykorzystaniem procedury kontrolnej (rys. 3) oraz zależności (1).



Rys. 2. Widok stanowiska badawczego do testów starzeniowych.

Procedura kontrolna: wyznaczenie C_{act}

1. Przerwanie aktualnie realizowanego wariantu starzeniowego po zakończeniu półcyklu rozładowania
 2. Doprowadzenie temperatury ogniwa do wartości równej 25°C
 3. Ładowanie ogniwa stałym prądem (CC) 1,3 A do napięcia 4,2 V, następnie stałym napięciem (CV) aż do osiągnięcia prądu 0,065 A
 4. 15-sekundowa przerwa
 5. Rozładowanie ogniwa prądem 2,6 A (CC) do napięcia 2,75 V
 6. Obliczenie pojemności ogniwa na podstawie oddanego ładunku (metodą Coulomb counting)
-

Rys. 3. Algorytm postępowania przyjęty do wyznaczenia aktualnej pojemności ogniw.

We wszystkich pracach wchodzących w skład rozprawy doktorskiej wykorzystano wyniki badań doświadczalnych uzyskanych zgodnie z procedurami opisanymi w niniejszym rozdziale.

3.4.4. Omówienie osiągniętych wyników

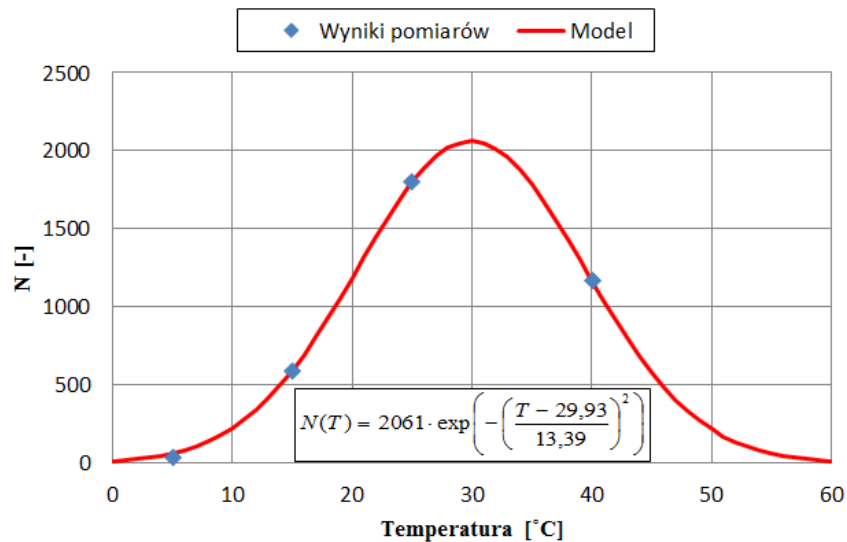
W większości artykułów naukowych panuje zgodność na temat parametrów pracy cyklicznej wpływających na proces zużycia ogniw litowo-jonowych, nie ma jej jednak w zakresie ich stopnia oddziaływania. W wielu proponowanych w literaturze światowej modelach pomijane są niektóre parametry pracy cyklicznej. W bardziej zaawansowanych uwzględnia się większość parametrów, ale często pomija się ich zmienność (uśrednia) lub uwzględnia w niewielkim zakresie, co sprawia, że użyteczność tych modeli jest ograniczona. Z tego powodu Autor rozpoczął prace badawcze od analizy wpływu wybranych parametrów pracy cyklicznej (temperatury otoczenia, prądu rozładowania oraz głębokości rozładowania) na liczbę cykli pracy, jakie może wykonać ogniwo NMC do osiągnięcia stanu zużycia $SOH = 80\%$. Opis badań i wyniki analiz Autor zaprezentował w artykule [DB-1]. Uzyskane wyniki badań starzeniowych przedstawiono w tabeli 1. W celu zbadania wpływu temperatury otoczenia wykorzystano warianty, w których wartości prądu rozładowania i głębokości rozładowania były jednakowe. Na podstawie uzyskanych wyników Autor zaproponował, aby wpływ temperatury otoczenia na liczbę cykli ogniwa odwzorowywać za pomocą funkcji Gaussa (rys. 4), opisanej zależnością (3). Zaletą zaproponowanej funkcji w stosunku do najczęściej stosowanych rozwiązań w postaci wielomianów (stopnia drugiego lub wyższego) lub zależności Arrheniusa jest większa dokładność w szerokim zakresie zmian temperatury.

$$N(T) = a \cdot e^{\left(-\left(\frac{T-b}{c}\right)^2\right)} \quad (3)$$

gdzie: N – liczba cykli, T – temperatura otoczenia, a , b , c – współczynniki modelu.

Tabela 1. Uzyskane wyniki z testów starzeniowych.

Lp.	Temperatura otoczenia [°C]	Prąd rozładowania [A]	Głębokość rozładowania [%]	Wykonana liczba cykli [-]
1	25	2,6	100	1800
2	25	5,2	100	1070
3	25	7,8	100	580
4	25	10,5	100	410
5	15	2,6	100	595
6	15	5,2	100	180
7	15	5,2	50	1075
8	15	7,8	100	1300
9	40	2,6	100	1170
10	40	5,2	100	678
11	40	7,8	100	395
12	40	7,8	77	776
13	40	7,8	50	1321
14	40	7,8	27	2473

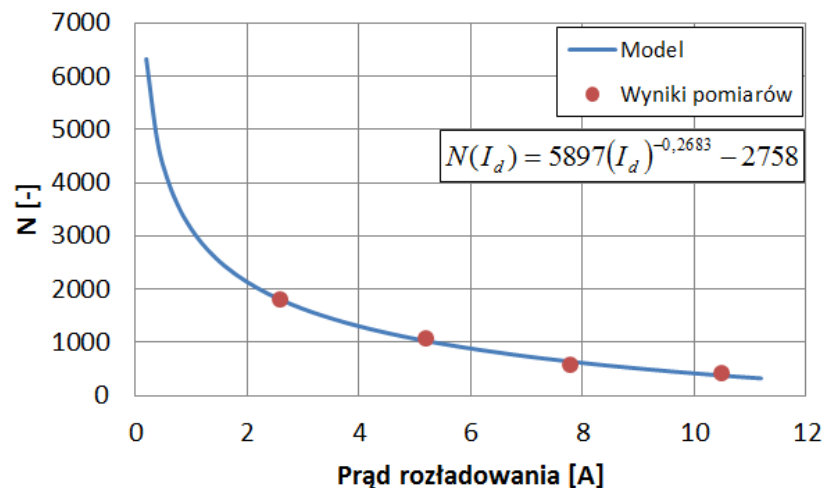


Rys. 4. Liczba cykli pracy w zależności od temperatury otoczenia (punkt pomiarowy w temperaturze 5°C uzyskano po opublikowaniu pracy [DB-1]).

Do oceny wpływu prądu rozładowania na trwałość, wyrażoną liczbą cykli pracy ogniwa, wykorzystano wyniki testów starzeniowych wykonanych w stałej temperaturze otoczenia oraz stałej głębokości rozładowania, które wynosiły odpowiednio 25°C i 100% (warianty nr 1, 2, 3, 4 z tabeli 1). Wpływ tego parametru z najmniejszym błędem odwzorowano funkcją potęgową (rys. 5) – zależność 4:

$$N(I_d) = d \cdot (I_d)^e + f \quad (4)$$

gdzie: I_d – prąd rozładowania, d, e, f – współczynniki modelu.

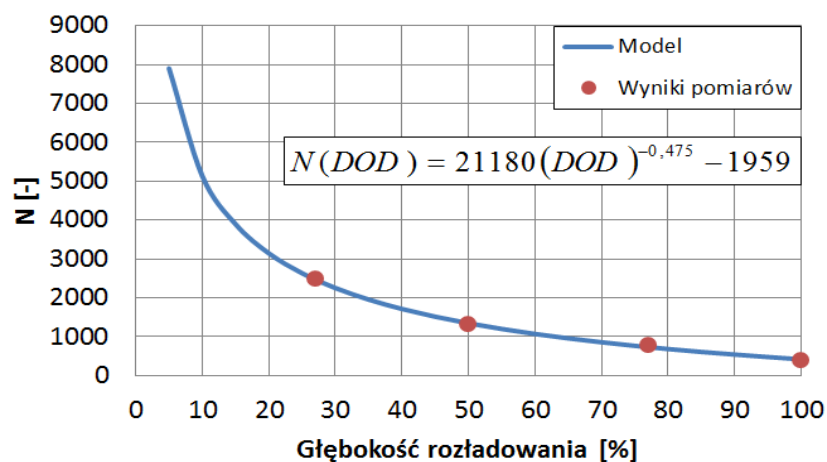


Rys. 5. Zależność liczby cykli pracy od prądu rozładowania.

W celu wyznaczenia wpływu głębokości rozładowania wykorzystano testy starzeniowe wykonane w temperaturze otoczenia równej 40°C przy prądzie rozładowania 7,8 A (warianty 11, 12, 13, 14 z tabeli 1). Jako funkcję odwzorującą wpływ tego parametru przyjęto funkcję potęgową (rys. 6):

$$N(DOD) = g \cdot (DOD)^h + i \quad (5)$$

gdzie: DOD – głębokość rozładowania, g, h, i – współczynniki modelu.



Rys. 6. Zależność liczby cykli pracy od głębokości rozładowania.

Współczynniki równań (3) – (5) zostały wyznaczone metodą najmniejszych kwadratów. Uzyskane wartości współczynników zestawiono w tabeli 2.

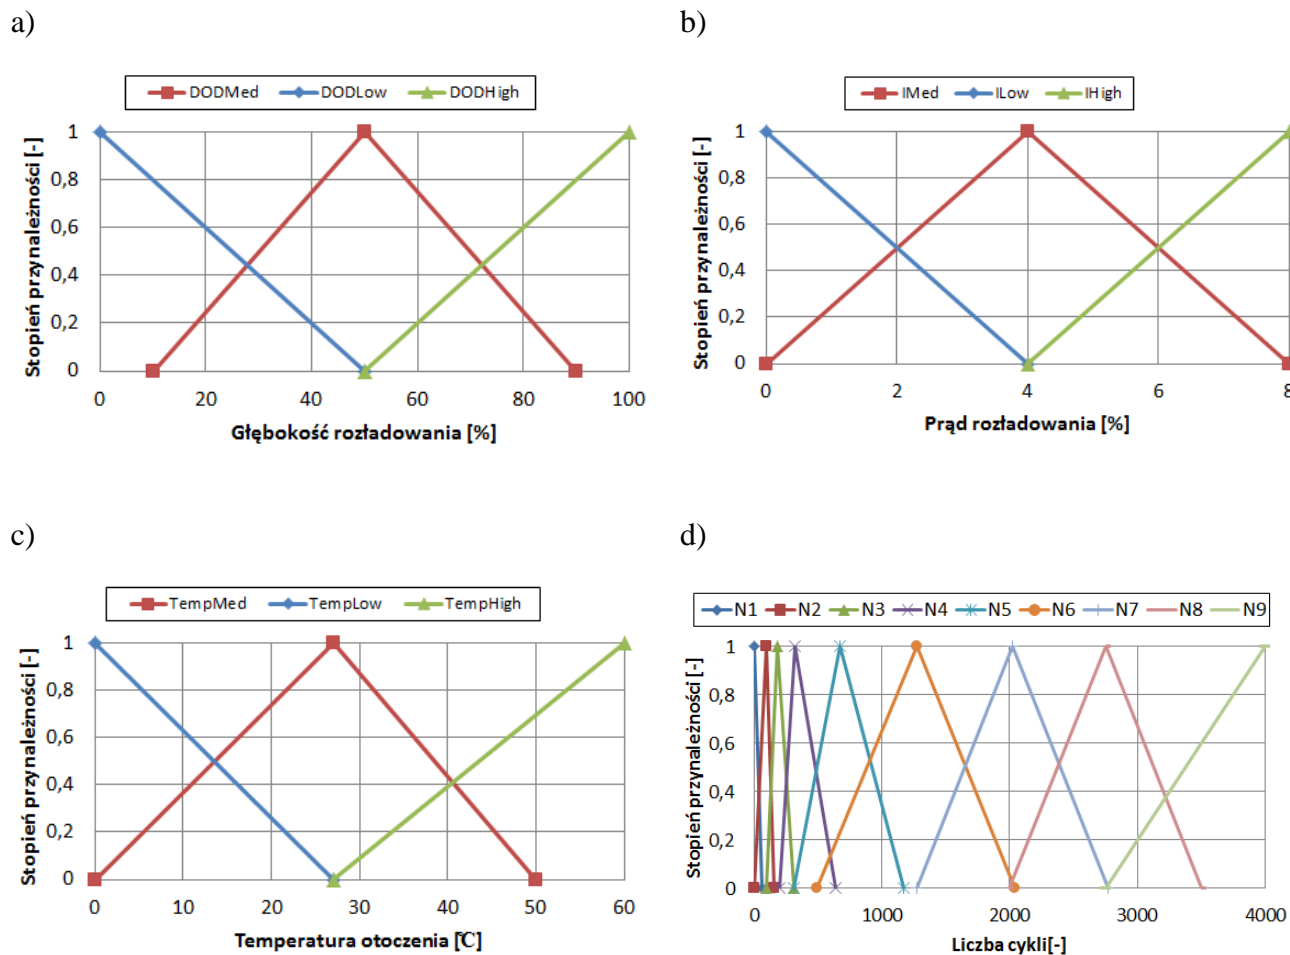
Tabela 2. Wartości wyznaczonych współczynników równań (3) – (5).

Współczynnik	Wartość
<i>a</i>	2061
<i>b</i>	29,93
<i>c</i>	13,39
<i>d</i>	5897
<i>e</i>	-0,2683
<i>f</i>	-2758
<i>g</i>	21180
<i>h</i>	-0,475
<i>i</i>	-1959

Następnie w pracy [DB-1] Autor zaproponował i zaimplementował nową koncepcję modelowania liczby cykli jakie wykona ogniwo NMC pracujące w stałych warunkach obciążeniowych i stałej temperaturze otoczenia. W autorskim rozwiązaniu wykorzystano system rozmyty typu Mamdaniego, należący do grupy modeli opartych na wiedzy. Parametrami wejściowymi modelu rozmytego były: temperatura otoczenia, prąd rozładowania oraz głębokość rozładowania, a parametrem wyjściowym była liczba cykli ładowanie–rozładowanie, jakie ogniwo wykona zanim osiągnie $SOH = 80\%$. Dla każdego parametru wejściowego zdefiniowano trzy trójkątne funkcje przynależności, natomiast dla parametru wyjściowego zdefiniowano 9 trójkątnych funkcji przynależności (rys. 7a – 7d). Wnioskowanie liczby cykli odbywa się na podstawie zdefiniowanej przez Autora bazy 27 reguł lingwistycznych, która zawiera wszystkie możliwe kombinacje parametrów wejściowych modelu. Wyniki wnioskowania liczby cykli przedstawiono na rys. 8a – 8c. Opracowany model został zweryfikowany dla 6 różnych przypadków testowych (tabela 3), a do określenia dokładności modelu wykorzystano błąd względny (zależność 6). Uzyskane wyniki charakteryzują się wysoką dokładnością w stosunku do wyników prezentowanych w podobnych modelach.

$$RE = \left(\frac{y_{meas} - y_{model}}{y_{meas}} \right) \cdot 100\% \quad (6)$$

gdzie: RE – błąd względny, y_{meas} – wartość zmierzona, y_{model} – wartość obliczona.




Rys. 7. Funkcje przynależności parametrów modelu: a) głębokości rozładowania, b) prądu rozładowania, c) temperatury otoczenia, d) liczby cykli.


Tabela 3. Wyniki weryfikacji modelu rozmytego.

Temperatura otoczenia [°C]	Prąd rozładowania [A]	Głębokość rozładowania [%]	Modelowana liczba cykli [-]	Zmierzona liczba cykli [-]	Błąd względny [%]
25	2,6	100	1705	1800	5,60
40	7,8	27	2152	2473	14,89
40	7,8	100	433	395	-8,84
40	7,8	50	1374	1321	-3,84
15	2,6	100	559	595	6,37
15	7,8	100	1385	1300	-6,13


a)



b)



c)



Rys. 8. Ilustracja wnioskowania liczby cykli modelu rozmytego: a) w funkcji głębokości rozładowania i temperatury otoczenia, b) w funkcji prądu rozładowania i temperatury otoczenia, c) w funkcji głębokości rozładowania i prądu rozładowania.

Następnie Autor kontynuował badania i analizy skupiając się na opracowaniu metody umożliwiającej wyznaczenie stanu zużycia ogniw litowo-jonowych podczas pracy w losowo zmiennym obciążeniu. Wyniki tych badań zaprezentował w pracy [DB-2], w której przedstawił autorską metodę modelowania procesu zużycia ogniw pracujących zarówno w stałych jak i dynamicznie zmiennych (losowych) warunkach obciążenia. W tej metodzie wykorzystano zaproponowany przez Autora wskaźnik służący do oceny szybkości zużycia ogniw elektrochemicznych zgodnie z zależnością:

$$\frac{dSOH}{dNeq} = \frac{SOH_{pre} - SOH_{act}}{Neq_{pre} - Neq_{act}} \quad (7)$$

gdzie: SOH_{pre} – stan zużycia wyznaczony podczas poprzedniej procedury kontrolnej, SOH_{act} – stan zużycia wyznaczony podczas bieżącej procedury kontrolnej, Neq_{pre} – liczba ekwiwalentnych cykli pracy wykonana przed poprzednią procedurą kontrolną, Neq_{act} – liczba ekwiwalentnych cykli pracy wykonana przed bieżącą procedurą kontrolną.

Stan zużycia był wyznaczany na podstawie zależności (1) zgodnie z procedurą kontrolną (rys. 3). Po każdym rozładowaniu i ładowaniu ogniwa, wyznaczano ekwiwalentną liczbę cykli pracy, powiększając ją o wartość zgodną z wzorem:

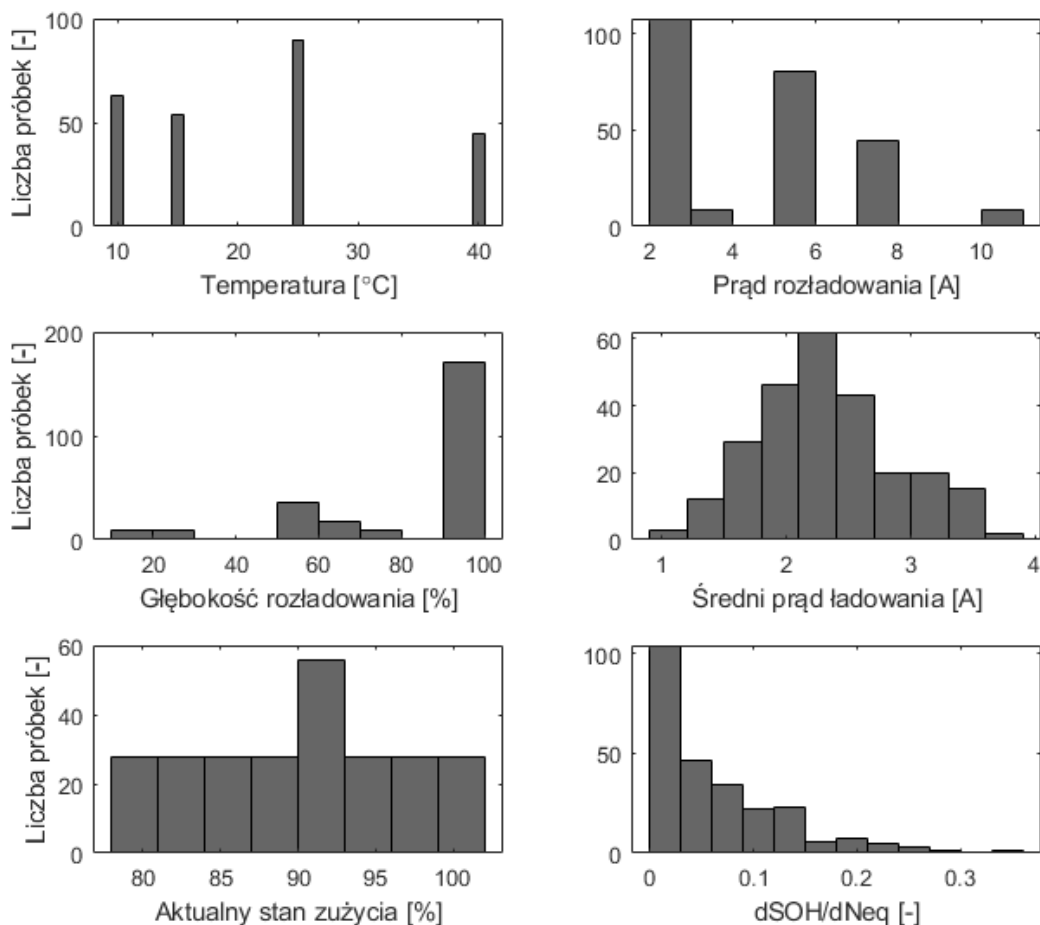
$$Neq = \frac{U_{dsch_avg} \cdot Q_{dsch} + U_{ch_avg} \cdot Q_{ch}}{U_{nom} \cdot Q_{tot}} \quad (8)$$

gdzie: U_{dsch_avg} – średnie napięcie ogniwa podczas półcyklu rozładowania, U_{ch_avg} – średnie napięcie ogniwa podczas półcyklu ładowania, Q_{ch} – ładunek dostarczony podczas ładowania, Q_{dsch} – ładunek pobrany podczas rozładowania, U_{nom} – napięcie znamionowe ogniwa, Q_{tot} – znamionowy ładunek pełnego cyklu pracy.

Proces opracowania modelu poprzedzony został analizą statystyczną danych eksperymentalnych 28 ogniw pracujących cyklicznie w stałych warunkach (załącznik 1). W tym celu zdefiniowano hipotezę zerową: *parametry pracy cyklicznej nie mają wpływu na zużycie ogniwa* oraz alternatywną: *parametry pracy cyklicznej mają wpływ na zużycie ogniwa*. Uwzględniając, że wpływ większości parametrów pełnego cyklu pracy na zużycie ogniwa jest nieliniowy, do wyznaczenia ich wpływu na $dSOH/dNeq$ Autor wykorzystał test nieparametryczny oparty na rangach Spearmana. Do weryfikacji postawionych wyżej hipotez wykorzystano parametr związany z istotnością statystyczną wyniku testu p -value. Przyjęto poziom istotności równy $\alpha = 0,05$. Histogram danych uczących przedstawiono na rys. 9, natomiast wyniki obliczeń współczynnika korelacji Spearmana oraz wartości p -value zestawiono w tabeli 4.

Tabela 4. Wartości współczynników korelacji Spearmana (ρ_s) i p -value dla parametrów pracy cyklicznej.

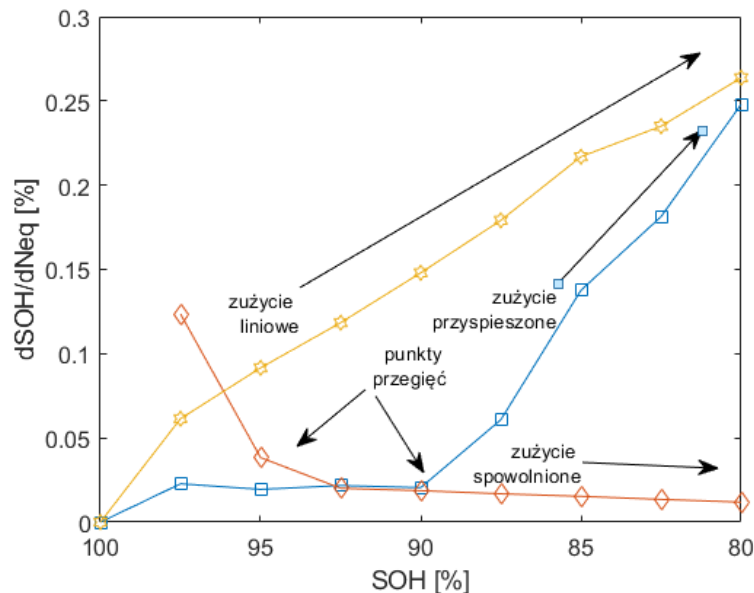
	Temperatura otoczenia	Prąd rozładowania	Głębokość rozładowania	Średni prąd ładowania	Aktualne SOH
ρ_s	-0,417	0,2398	-0,1363	-0,28	-0,624
p -value	<0,000001	0,000161	0,03371	0,000009	<0,000001



Rys. 9. Histogramy danych uczących.


Uzyskane wartości p -value dla wszystkich parametrów cyklu pracy są niższe od przyjętego poziomu istotności, co pozwoliło odrzucić hipotezę zerową i potwierdziło prawdziwość hipotezy alternatywnej. Postępując zgodnie z zasadami analiz statystycznych związanych z oceną siły wpływu (korelacji), przyjęto umiarkowanie wysoki wpływ dla $|\rho_s| > 0,6$, dla $0,6 > |\rho_s| > 0,4$ – wpływ umiarkowany, natomiast dla $|\rho_s| < 0,4$ – niski poziom wpływu. Na tej podstawie wykazano, że aktualny stan zużycia charakteryzuje się umiarkowanie wysokim wpływem na $dSOH/dNeq$, temperatura otoczenia – wpływem umiarkowanym, a najniższym wpływem na $dSOH/dNeq$ charakteryzują się: średni prąd ładowania, prąd rozładowania oraz głębokość rozładowania.

W pracy [DB-2] Autor analizował także szybkość zużycia ogniw na przestrzeni całego okresu eksploatacji. Wykazał, że przy określonych kombinacjach wartości parametrów pracy cyklicznej występują trzy wzorce szybkości degradacji ($dSOH/dNeq$). Dwa z nich charakteryzują się istotną dynamiką zmian szybkości zużycia ogniwa (widoczne obszary przegięć wykresów na rys. 10), po których następuje faza przyspieszonego lub spowolnionego zużycia. Trzeci wzorec wyróżnia się tym, że przyrost szybkości zużycia jest w przybliżeniu stały (wykres zbliżony do liniowego na rys. 10). Identyfikacja przyczyn oraz przewidywanie miejsc występowania punktów przegięć jest złożona ze względu na liczbę parametrów pracy oraz niemożliwość selektywnej analizy ich wpływu podczas pracy ogniwa. Ponadto wpływ tych parametrów jest najczęściej nieliniowy, co sprawia, że opracowanie matematycznych zależności określających $dSOH/dNeq$ w funkcji omawianych parametrów z akceptowalną dokładnością jest niemal niemożliwe.



Rys. 10. Przykłady trzech zidentyfikowanych wzorców dynamiki szybkości zużycia badanych ogniw.

Biorąc pod uwagę powyższe problemy, Autor zaproponował odejście od klasycznych metod modelowania i zastosowanie techniki wywodzącej się z dziedziny uczenia maszynowego z nadzorem – regresji opartej na procesach Gaussowskich (GPR). Zagadnienia związane z wykorzystaniem modeli opartych na jądrze Autor opisał szczegółowo w pracach [DB-2, DB-3] i wykorzystał do opracowania oryginalnego wieloparametrycznego modelu predykcji zużycia ogniw litowo-jonowych. Zmiennymi wejściowymi modelu były parametry: temperatura otoczenia, prąd rozładowania, głębokość rozładowania, średni prąd ładowania oraz dotychczasowy stan zużycia ogniwa. Uwzględnienie dotychczasowego stanu zużycia w całym okresie eksploatacji stanowiło istotny wkład w podejściu do modelowania. Autor również zwrócił uwagę na konieczność uwzględnienia w modelach zmiany wartości prądu ładowania spowodowanej skróceniem fazy ładowania stałym prądem w okresie eksploatacji ogniwa, co jest kolejnym udoskonaleniem w stosunku obecnie stosowanych metod modelowania. Do wyznaczania szybkości zużycia ($dSOH/dNeq$, zapisanego dla uproszczenia jako $y(x)$) Autor wykorzystał zależność (9), natomiast struktura modelu została przedstawiona na rys. 11.



Rys. 11. Graficzna reprezentacja modelu GPR. Zmienne x_i, y_i otoczone pełnymi okręgami są znanymi wartościami (zawartymi w zbiorze uczącym). Zmienne x_* są punktami testowymi (nie należącymi do zbioru uczącego), natomiast przerywanymi okręgami oznaczono parametry (y_*) przewidywane przez model. W prostokątach znajdują się zmienne ukryte modelu f .

$$y(x) = h(x)^T w + f(x) + \varepsilon \quad (9)$$

gdzie: $y(x)$ – szybkość zużycia, x – wektor parametrów wejściowych, $h(x)$ – zestaw funkcji bazowych, w – wektor współczynników funkcji bazowych, $f(x)$ – funkcja nazywana zmienną ukrytą o rozkładzie Gaussa, ε – szum o rozkładzie normalnym.

Na tym etapie Autor badał wpływ typu funkcji bazowych $h(x)$ oraz funkcji jądrowej $k(x, x^*)$ na dokładność modelu zarówno dla zestawu danych uczących, stanowiących wyniki testów starzeniowych uzyskanych przy stałym obciążeniu (zgodnie z warunkami przedstawionymi w załączniku 1), jak i podczas dynamicznie zmiennego obciążenia, generowanego w sposób losowy. Przed procesem uczenia modelu wszystkie dane uzyskane z eksperymentów zostały ustandaryzowane zgodnie z technikami obróbki danych (opisanymi w artykule [DB-2]) i przetworzone do postaci zbioru uczącego. Wyniki procesu uczenia (porównania odpowiedzi modelu z wartością uzyskaną z eksperymentu) przedstawiono w załączniku 2. Do oceny dokładności modelu wykorzystano powszechnie stosowane miary – średni procentowy błąd bezwzględny (*MAPE*) oraz błąd średniokwadratowy (*RMSE*). Szczegółową analizę porównawczą pięciu wariantów modeli przeprowadzono i przedstawiono w pracy [DB-2], a wyniki zestawiono w tabeli 5.

Tabela 5. Wyniki analizy porównawczej pięciu wariantów modeli uczenia nadzorowanego.

Wariant modelu	$k(x, x^*)$	$h(x)$	<i>MAPE</i> [%]	R^2 [-]	<i>RMSE</i> [-]
model 1	Rational Quadratic	constant	6,03	0,96	0,0116
model 2	Matern 5/2	constant	5,15	0,96	0,0117
model 3	Exponential	constant	0,07	0,94	0,0149
model 4	Squared Exponential	linear	7,37	0,96	0,0117
model 5	Matern 3/2	linear	2,27	0,96	0,0119

Kolejnym etapem badań, mającym na celu wybór najlepszego spośród testowanych wariantów modeli, była analiza ich dokładności dla pracy cyklicznej ogniów przy dynamicznie zmiennym obciążeniu. Do realizacji tego zadania Autor opracował aplikację komputerową służącą do sterowania dwukierunkowych ładowarek Pulsar 3 oraz Pulsar 3+ w sposób umożliwiający generowanie losowo zmiennego obciążenia i ładowania. Wartości prądów rozładowania losowane były z zakresu od 2 A do 6 A, natomiast wartości prądów ładowania z zakresu od 2 A do 4 A. Testy prowadzone były w dwóch różnych temperaturach otoczenia (10°C oraz 15°C) oraz przy dwóch poziomach głębokości rozładowania ($DoD = 16\%$ i $DoD = 48\%$) w zakresie od $SOH = 100\%$ do $SOH = 80\%$. Liczbę losowań poszczególnych wartości prądów zestawiono w tabeli 6. Wylosowane sekwencje obciążenia zostały wprowadzone do modelu, po czym przeprowadzono symulację procesu zużycia ogniów. Jako kryterium wyboru ostatecznej struktury modelu w pracy [DB-2] przyjęto zdolność do prawidłowego odwzorowania stanu zużycia podczas losowo zmiennego obciążenia ogniwa w trakcie całego okresu eksploatacji. Do oceny dokładności odwzorowania zastosowano błąd względny. Spośród testowanych modeli najlepsze odwzorowanie uzyskano dla funkcji bazowych typu liniowego oraz funkcji jądrowej typu Matern 3/2 (zależność 10) – model 5. Dla tego wariantu modelu uczenia maszynowego błąd *APE* nie przekroczył 5% w obu przypadkach testowych, co potwierdza wysoką efektywność zaproponowanej metody.

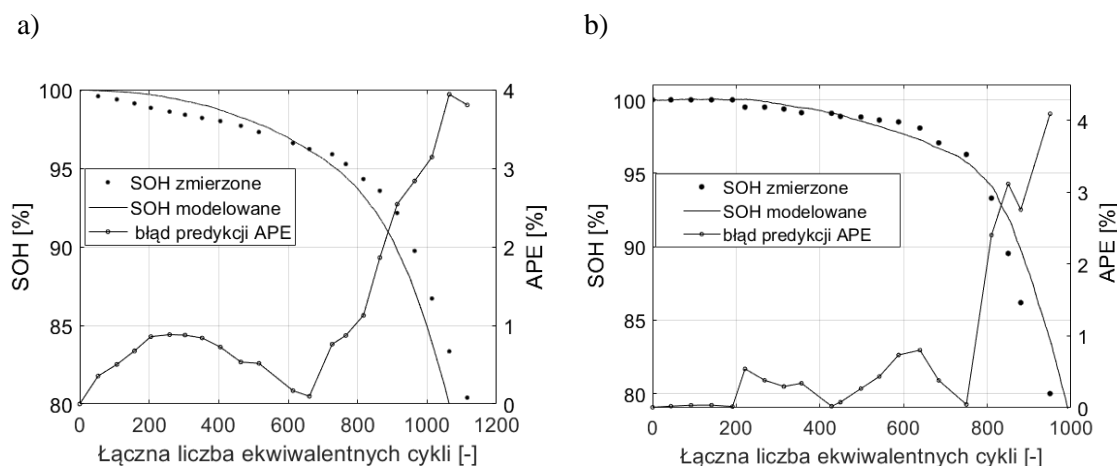
Tabela 6. Liczba wylosowanych poszczególnych wartości prądów w celu weryfikacji modelu podczas losowo zmiennego obciążenia

Wylosowany prąd [A]	Test 1 ($T=10^{\circ}\text{C}$, $DoD=16\%$)	Test 2 ($T=15^{\circ}\text{C}$, $DoD=48\%$)
Półcykl rozładowania		
2	1354	202
3	1514	227
4	1643	192
5	1620	236
6	1491	190
Półcykl ładowania		
2	2408	344
3	2722	351
4	2513	356

Wyznaczony z wykorzystaniem modelu 5 stan zużycia (SOH) oraz błąd modelu (APE) dla dynamicznie zmiennego obciążenia w obu przypadkach testowych przedstawiono na rys. 12a – 12b.

$$k_{Mat3/2} = \sigma_f^2 \left(1 + \frac{\sqrt{3}r}{\sigma_l} \right) \exp\left(-\frac{\sqrt{3}r}{\sigma_l} \right) \quad (10)$$

gdzie: σ_f – odchylenie standardowe, σ_l – długość charakterystyczna, r – długość Euklidesowa.



Rys. 12. Wyniki weryfikacji modelu 5 podczas losowo zmiennego obciążenia: a) Test 1, b) Test 2.

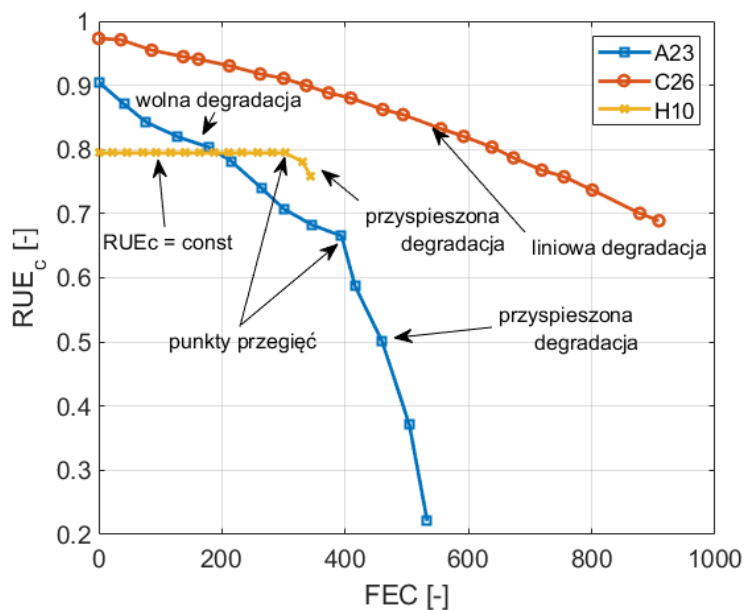
W pracy [DB-3] Autor zajął się zagadnieniem predykcji dostępnej energii użytecznej ogniwa typu NMC z uwzględnieniem dotychczasowego stanu zużycia. Na podstawie wyników badań eksperymentalnych 29 ogniw pracujących cyklicznie w różnych warunkach temperaturowych i obciążeniowych (załącznik 3), Autor analizował ich zdolność do gromadzenia energii na przestrzeni całego okresu eksploatacji (od $SOH = 100\%$ do $SOH = 80\%$). Do oceny przyjęto wskaźnik opisany zależnością (11), określający względną ilość energii użytecznej, którą ogniwo może wymienić w pojedynczym cyklu pracy (RUE_c). Ładunek dostarczony i pobrany podczas pracy cyklicznej obliczony był za pomocą metody Coulomb counting.

$$RUE_c = \frac{Q_{dsch} \cdot U_{ave_dsch} + Q_{ch} \cdot U_{ave_ch}}{2 \cdot C_{nom} \cdot U_{nom}} \quad (11)$$

gdzie: U_{ave_dsch} – średnie napięcie ogniwa podczas półcyklu rozładowania, U_{ave_ch} – średnie napięcie ogniwa podczas półcyklu ładowania, U_{nom} – napięcie znamionowe ogniwa, C_{nom} – pojemność znamionowa ogniwa, Q_{ch} – ładunek dostarczony podczas ładowania, Q_{dsch} – ładunek pobrany podczas rozładowania.

W badaniach analizowano wpływ wartości parametrów pracy cyklicznej na zdolność ogniwa do wymiany RUE_c . W pracy [DB-3] wykazano, że najwyższa utrata zdolności do wymiany RUE_c dotyczy ogniw obciążanych prądem o wartości 7,8 A. W tych przypadkach RUE_c obniżyło się o 39,8–71,8%. Skutek ten zaobserwowano podczas badań niezależnie od temperatury ogniwa. Ponadto Autor wykazał, że dla ogniw rozładowywanych powyżej 70% głębokości rozładowania, RUE_c charakteryzuje się różną dynamiką zmian w trakcie rozpatrywanego okresu eksploatacji. W zależności od kombinacji wartości parametrów pracy cyklicznej rozpoznano trzy wzorce dynamiki zmian RUE_c (rys. 13):

- 1) o charakterystyce w przybliżeniu liniowej (ogniwo „C26”),
- 2) wolny spadek w pierwszym etapie eksploatacji, po którym następowała faza przyspieszonej utraty zdolności do wymiany energii (ogniwo „A23”),
- 3) po fazie oddawania założonego ładunku następowała faza przyspieszonej utraty zdolności do wymiany energii (ogniwo „H10”).



Rys. 13. Charakterystyki zmian RUE_c badanych ogniw NMC (wybrane warianty z załącznika 3).

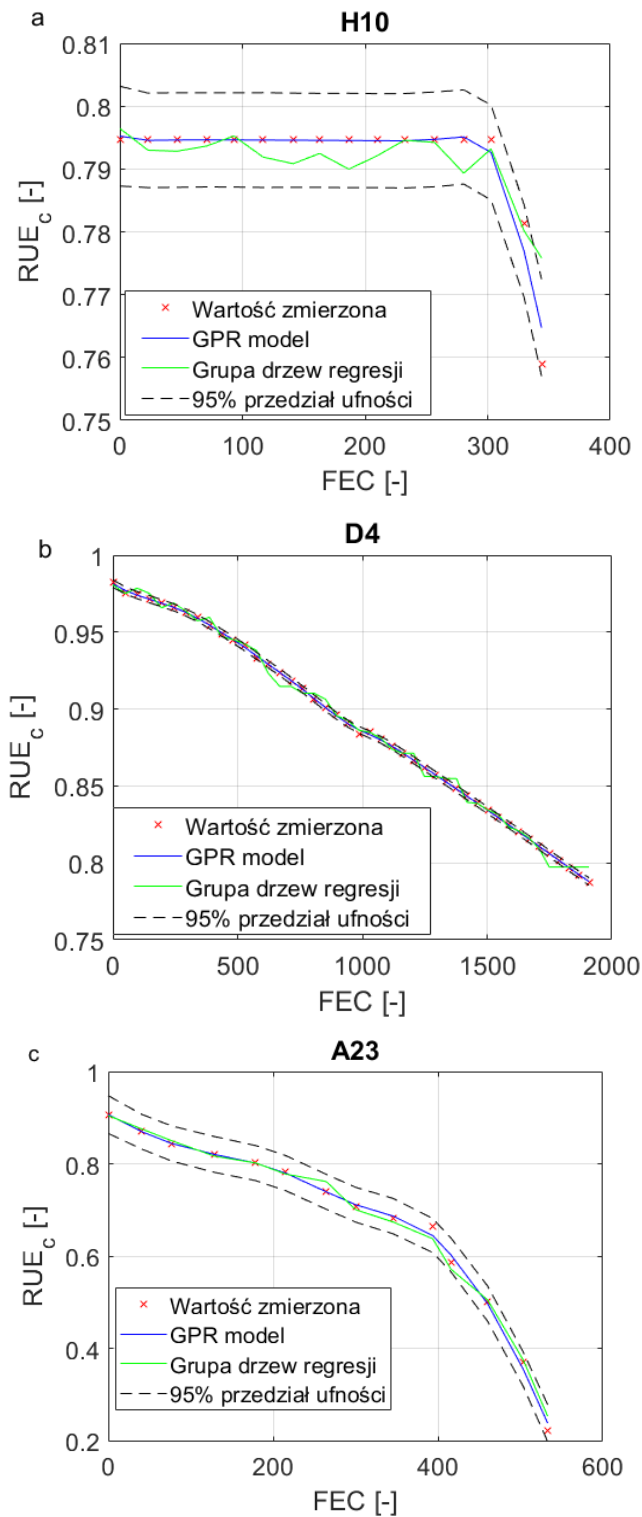
Z rys. 13 wynika, że ogniwa pracujące w różnych warunkach charakteryzują się wysoką rozbieżnością zdolności do wymiany RUE_c , pomimo wykonania takiej samej liczby ekwiwalentnych cykli pracy (FEC). Świadczy to o złożoności prezentowanego problemu naukowego, jak i o konieczności stosowania zaawansowanych metod modelowania. Z tego powodu, a także biorąc pod uwagę zalety modeli uczenia maszynowego z nadzorem, Autor w pracy [DB-3] zdecydował się na porównanie różnych metod z tej grupy do odwzorowania zdolności ogniwa do wymiany RUE_c w całym okresie jego eksploatacji. Danymi wejściowymi modelu były parametry pełnego cyklu pracy: średnia temperatura ogniwa w trakcie pełnego cyklu pracy (T_s), prąd rozładowania (I_d), głębokość rozładowania (DoD), średni prąd ładowania (I_{ch_avg})

oraz liczba ekwiwalentnych cykli pracy (zakładając, że ekwiwalentny cykl pracy równy jest wymianie przez ogniwo znamionowej energii – 18,876 Wh). Predykowanym parametrem była relatywna energia użyteczna (RUE_c), jaką ogniwo może wymienić w trakcie pojedynczego cyklu pracy. Autor wykonał analizę porównawczą procedury uczenia dla następujących modeli opartych na uczeniu maszynowym: pojedynczym drzewie regresji, grupie drzew regresji, maszyny wektorów wspierających oraz regresji opartej na procesach Gaussowskich (GPR). Do zestawu uczącego wybrano dane uzyskane z 20 wariantów procedur starzeniowych ogniw, charakteryzujących się głębokim rozładowaniem ($DoD > 70\%$), w których znajdowało się łącznie 311 zestawów danych pomiarowych. Wszystkie zestawy poddano standaryzacji zgodnie z zasadami obróbki danych. Szczegółowa analiza porównawcza procesu uczenia została przedstawiona w pracy [DB-3], w której wykazano, że spośród testowanych modeli, najlepsze dopasowanie do zbioru danych uczących uzyskano dla modelu GPR. Dla każdego zestawu danych uczących odpowiedź modelu była zawarta w przyjętym przedziale ufności (na poziomie 95%), a średni błąd $MAPE$ dla wszystkich próbek wyniósł 0,05%, co świadczy o wysokim dopasowaniu modelu. Przykładowe wyniki procesu uczenia dla trzech wzorców dynamiki zmian RUE_c wyznaczone z wykorzystaniem dwóch modeli charakteryzujących się najniższym błędem $MAPE$ przedstawiono na rys. 14a – 14c.

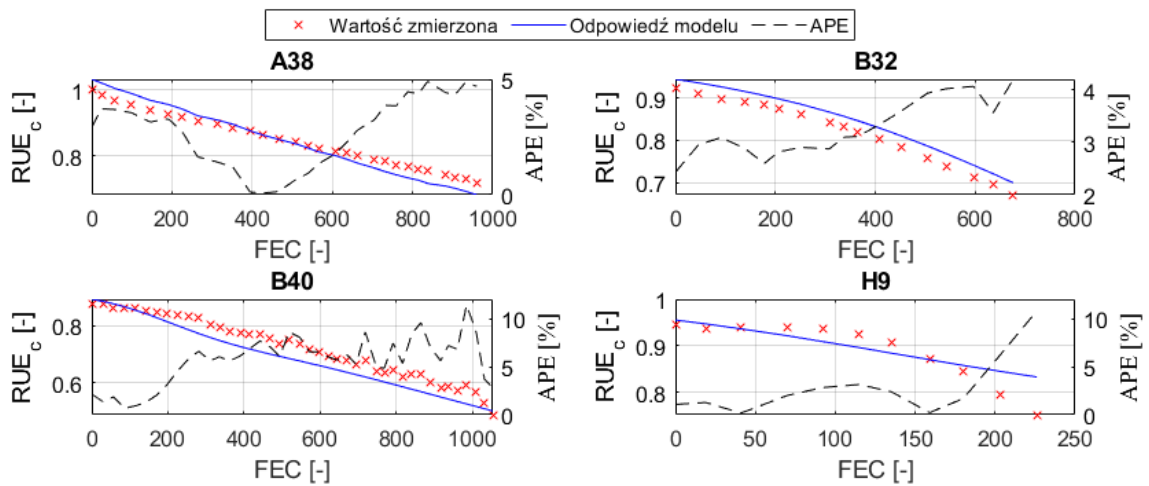
W dalszej części pracy [DB-3] przeprowadzono weryfikację modelu, do której wykorzystano 4 ogniwa obciążone profilami niewykorzystanymi w procesie uczenia (zbiór weryfikacyjny zawierał 99 zestawów danych). Weryfikacja polegała na porównaniu wartości RUE_c uzyskanych podczas eksperymentu z wartościami wyznaczonymi przez model w całym okresie eksploatacji. Do oceny dokładności modelu zastosowano wskaźniki $MAPE$ oraz APE . Wyniki zestawiono w tabeli 7, a uzyskane charakterystyki przedstawiono na rys. 15. Uzyskane wyniki świadczą o wysokiej zdolności modelu do wyznaczania RUE_c w dowolnych warunkach obciążeniowych, co zostało potwierdzone niską wartością $MAPE$. W trzech przypadkach testowych $MAPE$ wyniósł około 3%, natomiast dla ogniwa „B40” błąd nieznacznie przekroczył 5%. Z kolei błąd APE dla ogniw „B40” oraz „H9” w końcowej fazie eksploatacji ogniw osiągał poziom 10%. Przyczyny występowania błędów APE zostały wyczerpująco omówione w pracy [DB-3].

Tabela 7. Wyniki procesu weryfikacji modelu dla nowych profili obciążenia.

ID ogniwa	T_s	I_d	DoD	I_{ch_avg}	$MAPE$
	[°C]	[A]	[%]	[A]	[%]
B40	30,3	5,2	100	2,2	5,63
H9	35,3	2,6	100	2,85	2,88
A38	54,6	5,2	100	2,63	2,77
B32	39,7	5,2	100	2,47	3,26



Rys. 14. Wyniki procesu uczenia modelu GPR oraz modelu grupy drzew regresji dla trzech zaobserwowanych typów dynamiki zmian RUE_c : a) po fazie oddawania zadanego ładunku nastąpiła faza przyspieszonej utraty zdolności do oddawania energii, b) w przybliżeniu liniowa, c) po wykonaniu przez ogniwo około 400 FEC nastąpiła faza przyspieszonej utraty zdolności do oddawania energii.



Rys. 15. Wyniki procedury weryfikacji modelu predykcji RUE_c .

Ze względu na brak zgodności w światowej literaturze na temat wpływu poszczególnych czynników na proces zużycia ogniów litowo-jonowych, Autor w pracy [DB-3] przeprowadził analizy umożliwiające ocenę wpływu parametrów modelu na wartość RUE_c . Badania te polegały na określeniu istotności oraz wyznaczeniu ilościowego wpływu parametrów wejściowych modelu. Ocenę ilościową przeprowadzono analizując parametry selektywnie oraz ich kombinacje. Do tego celu wykorzystano metody wyjaśnialnego uczenia maszynowego. W celu określenia istotności parametrów modelu predykcyjnego wykorzystano metodę istotności zmiennych (ang. variable importance), natomiast do wyznaczenia ilościowego wpływu parametrów pracy cyklicznej na RUE_c zastosowano metodę zakumulowanych efektów lokalnych (ang. accumulated local effects) pierwszego i drugiego rzędu.

Wykorzystując metodę istotności zmiennych wyznaczono błędy modelu poprzez permutacje wartości każdego parametru modelu oraz wskaźniki istotności. Algorytm wyznaczania istotności zmiennych przedstawiono na rys. 16. Jako funkcję straty przyjęto $RMSE$. Uśrednione wartości wskaźnika istotności zmiennych (VI) oraz odchylenia standardowego (σ) zestawiono w tabeli 8.

Procedura wyznaczania istotności zmiennych (VI)	
Wejście:	<ul style="list-style-type: none"> x – wektor zmiennych objaśniających y – wektor zmiennej objaśnianej (zmierzonej) f – model $L(y,f)$ – funkcja straty ($RMSE$)
Kroki:	<ol style="list-style-type: none"> 1. Wyznaczenie oryginalnego błędu modelu $L^0=L(y,f(x))$ 2. Dla każdej zmiennej objaśniającej x_j: <ol style="list-style-type: none"> a. Wygenerowanie nowej macierzy zmiennych x^p poprzez permutację zmiennych x_j w macierzy x. b. Wyznaczenie predykcji modelu y na podstawie permutowanej macierzy x^p. c. Obliczenie błędu modelu na podstawie predykcji z danych permutowanych $L_j=L(y,f(x^p))$. d. Obliczenie wskaźnika istotności zmiennych $VI_j=L_j-L_0$ 3. Posortowanie zmiennych objaśniających według malejącego VI
Wyjście:	<ul style="list-style-type: none"> VI_j – istotność zmiennej objaśniającej

Rys. 16. Algorytm wyznaczania istotności zmiennych.

Tabela 8. Wartości istotności parametrów wejściowych modelu predykcyjnego.

Parametr	T_s	I_d	DoD	I_{ch_avg}	FEC
\bar{V}_I	0,120042	0,147475	0,048705	0,056989	0,16758
σ	0,001375	0,001651	0,000866	0,000554	0,00161

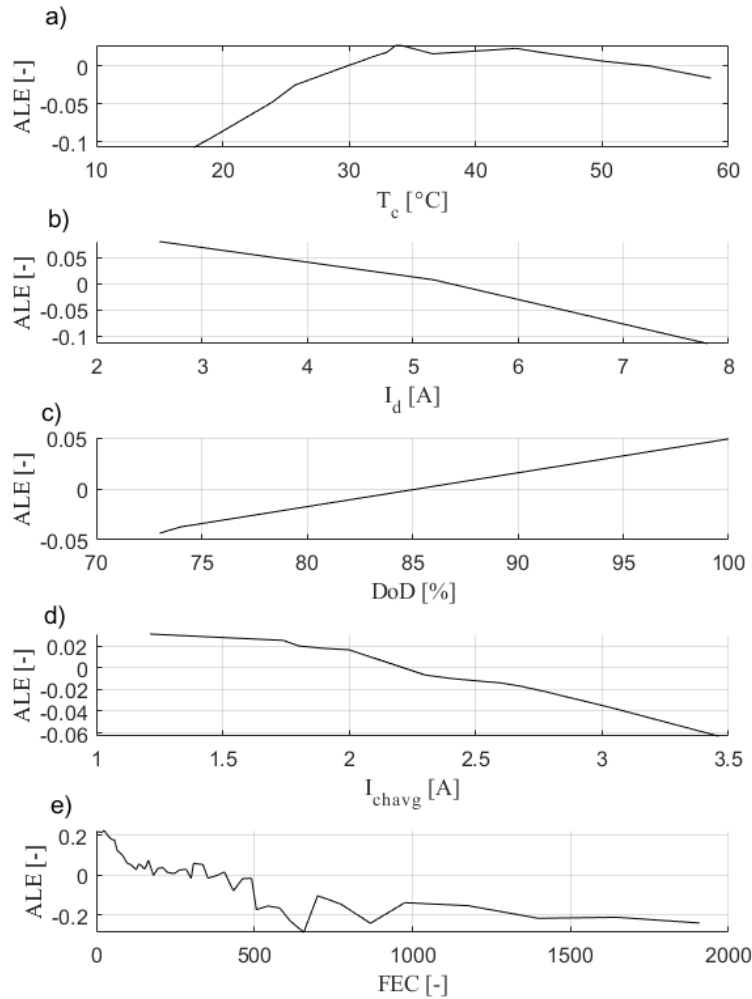
Na podstawie uzyskanych wyników stwierdzono, że najwyższy wpływ na RUE_c ma liczba ekwiwalentnych cykli pracy, następnie prąd rozładowania i średnia temperatura ogniwa.

W celu określenia ilościowego wpływu jaki poszczególne parametry pracy cyklicznej mają na przewidywaną wartość RUE_c (nazywany wpływem głównym), Autor zastosował metodę zakumulowanych efektów lokalnych pierwszego rzędu (ALE). Funkcja ALE pierwszego rzędu jest opisana wzorem (12) i odzwierciedla różnicę między RUE_c wyznaczaną przez model a średnią wartością RUE_c obliczaną dla parametrów o wartościach znajdujących się w otoczeniu rozpatrywanych punktów.

$$ALE(x_1) = \int_{\min(x_1)}^{x_1} E \left[\frac{\partial f(x_1, x_2)}{\partial x_1} \Big|_{x_1 = z_1} \right] dz_1 + c_1 \quad (12)$$

gdzie: $\frac{\partial f(x_1, x_2)}{\partial x_1}$ – reprezentuje efekt lokalny wpływu zmiennej x_1 na wyznaczaną wartość f w punkcie (x_1, x_2) , $\min(x_1)$ – dolna granica rozpatrywanego zakresu zmiennej, c_1 – stała dobrana w celów pionowego wycentrowania wykresu,

Charakterystyki wpływów głównych poszczególnych parametrów wejściowych modelu przedstawiono na rys. 17a – 17e. Z rys. 17a wynika, że najwyższe wartości RUE_c uzyskać można podczas pracy ogniwa w zakresie temperatur od 30°C do 52°C. Poza tym zakresem przewidywana wartość RUE_c będzie niższa od wartości średniej (a w temperaturze poniżej 20°C wartość ALE obniża się nawet o około 0,1). Na rys. 17b zauważyć można, że wartość ALE maleje proporcjonalnie do prądu rozładowania, osiągając wartość średnią przy prądzie 5,2 A, natomiast przy prądzie 7,8 A wartość -0,1. Podobna zależność zachodzi dla średniego prądu ładowania (rys. 17d), w którym wartość średnia przypada dla 2,25 A, natomiast dla prądu 3,4 A ALE osiąga -0,06. Zależność ALE od głębokości rozładowania w całym rozpatrywanym zakresie jest liniowa (rys. 17c). Z rys. 17e wynika, że ogniwa, które wykonały mniej niż 200 FEC były zdolne do wymiany największej ilości RUE_c – dla nowych ogniw pracujących w korzystnych warunkach ALE wynosiło nawet 0,2. Stosunkową wysoką zdolnością do gromadzenia energii charakteryzowały się również ogniwa, które wykonały od 200 do 500 cykli (ALE utrzymywało się na średnim poziomie). Natomiast w przypadku ogniw, które wykonały ponad 500 FEC , zaobserwowano istotny spadek ALE .

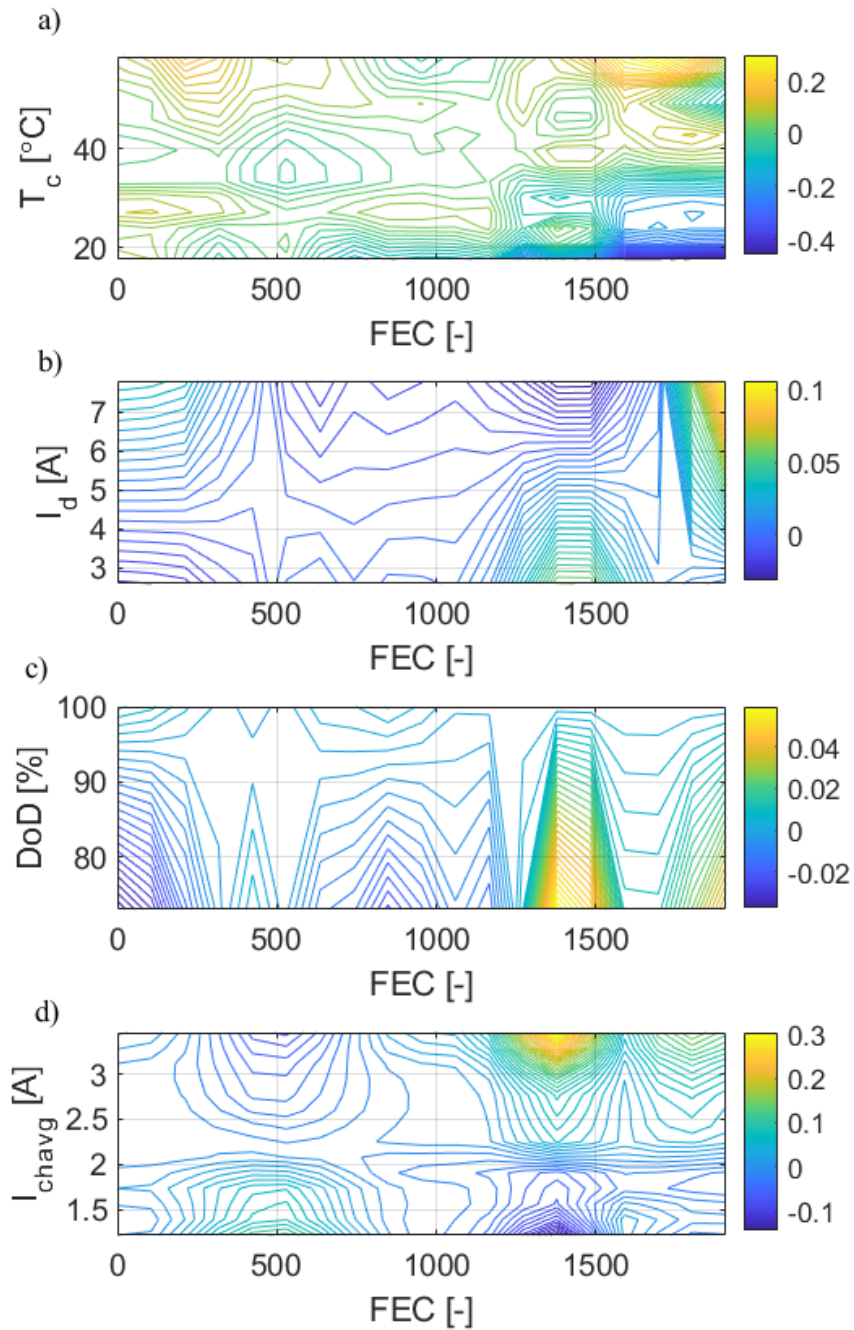


Rys. 17. Charakterystyki zakumulowanych efektów lokalnych pierwszego rzędu (wpływ główny) w funkcji: a) średniej temperatury ogniwa, b) prądu rozładowania, c) głębokości rozładowania, d) średniego prądu ładowania, e) liczby ekwiwalentnych cykli.

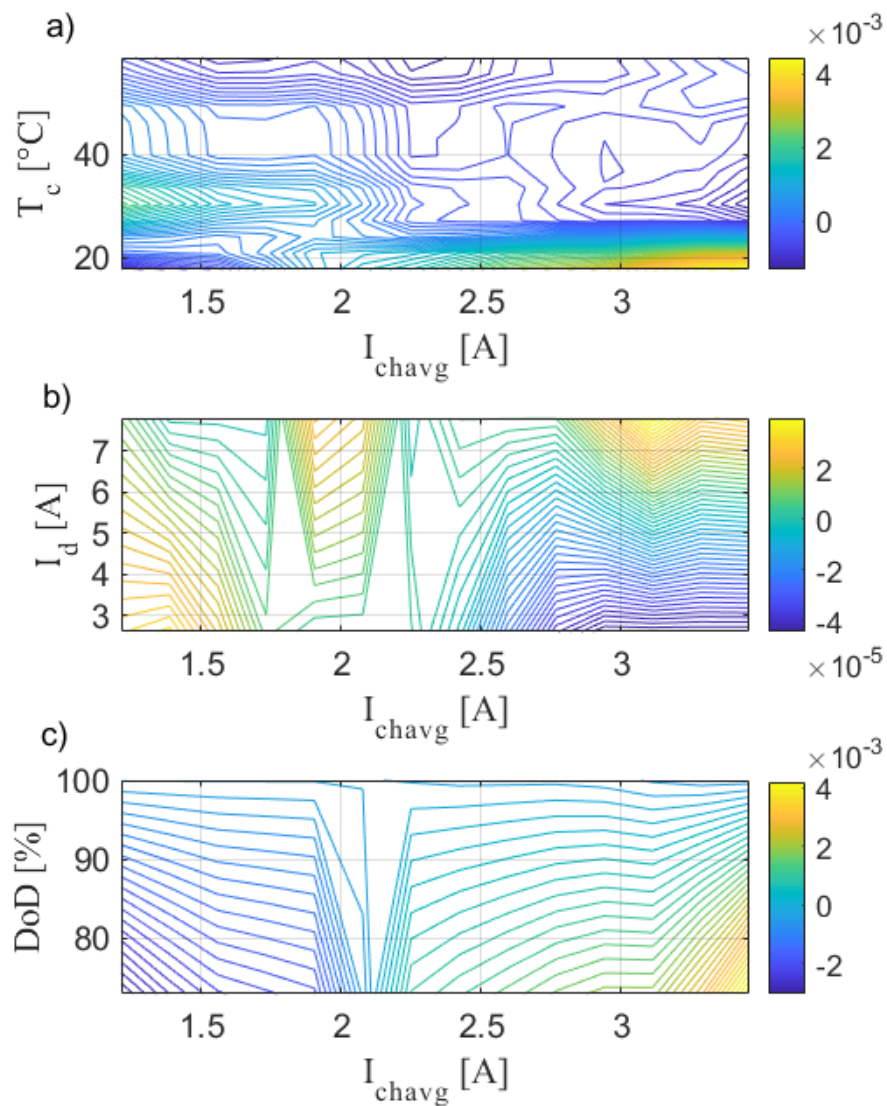
Ponadto Autor w pracy [DB-3] badał również wpływ wszystkich możliwych kombinacji par parametrów modelu na RUE_c . Do tego celu wykorzystano metodę zakumulowanych efektów lokalnych drugiego rzędu, dzięki której możliwe jest wyznaczenie wpływu par parametrów z pominięciem ich wpływu głównego (wyznaczonego metodą ALE pierwszego rzędu). Efekt wpływu dwóch parametrów modelu obliczono na podstawie zależności:

$$ALE(x_1, x_2) = \int_{\min(x_1)}^{x_1} \int_{\min(x_2)}^{x_2} E \left[\frac{\partial f(x_1, x_2, x_{\{1,2\}})}{\partial x_1 \partial x_2} \right]_{x_1 = z_1, x_2 = z_2} dz_1 dz_2 \quad (13)$$

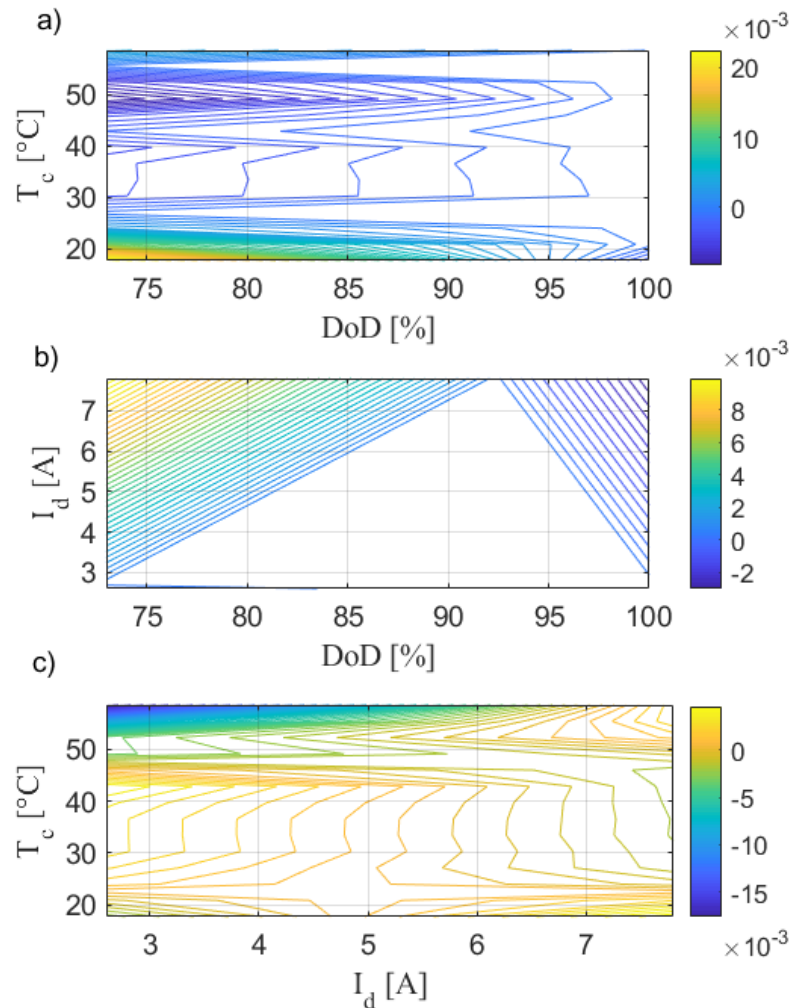
Uzyskane wyniki ALE drugiego rzędu przedstawiono w postaci map wartości na rys. 18 – 20. Umożliwiły one ilościowe określenie wpływu par parametrów pracy cyklicznej na RUE_c . Najwyższymi wartościami ALE charakteryzują się kombinacje z parametrem FEC , w szczególności: $ALE(FEC, T_c)$, $ALE(FEC, I_d)$, $ALE(FEC, I_{ch_avg})$. Pary $ALE(FEC, DoD)$, $ALE(T_c, I_d)$ oraz $ALE(T_c, DoD)$ wykazują wpływ umiarkowany, natomiast pozostałe kombinacje par parametrów wykazują najniższe wartości ALE .



Rys. 18. Wartości zakumulowanych efektów lokalnych dla poszczególnych kombinacji par parametrów modelu: a) średniej temperatury ogniwa i liczby ekwiwalentnych cykli, b) prądu rozładowania i liczby ekwiwalentnych cykli, c) głębokości rozładowania i liczby ekwiwalentnych cykli, d) średniego prądu ładowania i liczby ekwiwalentnych cykli.



Rys. 19. Wartości zakumulowanych efektów lokalnych dla poszczególnych kombinacji par parametrów modelu: a) średniej temperatury ogniwa i średniego prądu ładowania, b) prądu rozładowania i średniego prądu ładowania, c) głębokości rozładowania i średniego prądu ładowania.



Rys. 20. Wartości zakumulowanych efektów lokalnych dla poszczególnych kombinacji par parametrów modelu: a) średniej temperatury ogniwa i głębokości rozładowania, b) prądu rozładowania i głębokości rozładowania, c) średniej temperatury ogniwa i prądu rozładowania.

Ostatnim etapem prac badawczych zrealizowanych w ramach rozprawy doktorskiej była analiza porównawcza efektywności opracowanych przez Autora metod z rozwiązaniami opisanymi w renomowanych czasopismach naukowych. Analiza obejmowała określenie liczby oraz zakresów zmienności parametrów wejściowych modelu, typu modelu oraz uzyskanej dokładności (z wykorzystaniem *MAPE*). W analizie porównawczej nie ujęto powszechnie stosowanych metod uproszczonych, np. takich, w których proces zużycia modelowano w funkcji pojedynczego parametru pracy cyklicznej – ze względu na znacząco niższą dokładność. Skupiono się natomiast na różnych nowatorskich koncepcjach opisanych w literaturze światowej, które opracowano oraz weryfikowano na różnych zestawach danych. Na podstawie wykonanej analizy stwierdzić można, iż opracowane przez Autora wieloparametryczne modele umożliwiają predykcję procesu zużycia dla szerokiego zakresu zmienności parametrów wejściowych, dzięki temu w całym okresie eksploatacji ogniw uzyskano wyższą dokładność niż w obecnie stosowanych metodach – szczegółowe wyniki zestawiono w tabeli 9.

Tabela 9. Analiza porównawcza struktur oraz efektywności modeli predykcji procesu zużycia ogniw litowo-jonowych.

Źródło (rok wydania)	Typ modelu	Parametry wejściowe	Zakres zmienności parametrów wejściowych	Parametr wyjściowy	Zakres zmienności parametru wyjściowego	Błąd modelu (MAPE) [%]	Uwagi
[29] (2015)	Metoda Bayesa	liczba cykli prąd rozładowania pojemność ogniwa	0 – 1958 0,5C, 1C 1,1 Ah, 1,35 Ah	pojemność	0,9 Ah – 1,35 Ah	8,7%	Brak zmienności temperatury, głębokości rozładowania i prądu ładowania. Model nie zidentyfikował zmian dynamiki procesu zużycia.
[31] (2017)	Sztuczna sieć neuronowa	stan naładowania rezystancja omowa rezystancja dynamiczna pojemność dynamiczna	20% – 100% stanu naładowania ogniwa	SOH	103,3% – 74%	5,3%	Brak zmienności temperatury. Parametry schematu zastępczego ogniwa pierwszego rzędu wyznaczone dla różnego stopnia zużycia.
[50] (2019)	Regresja liniowa z regularyzacją	dQ/dV	2,0 V – 3,6 V	liczba cykli	0 – 2237	9,1% (najlepszy wynik)	Testowano trzy warianty modelu. Brak zmienności prądu rozładowania, temperatury i głębokości rozładowania.
[52] (2018)	Głębokie uczenie	prąd ładowania temperatura głębokość rozładowania prąd rozładowania	1,5 A 25°C – 40°C (brak komory) 100% 0,2C	pojemność	100% – 70%	88% (najlepszy wynik)	Testowano cztery warianty modelu. Model nie odwzorowuje dynamiki zmian procesu zużycia.
[53] (2019)	Sztuczna sieć neuronowa	prąd ładowania temperatura głębokość rozładowania prąd rozładowania	1,5 A 25°C – 40°C (brak komory) 100% 0,2C	pojemność	100% – 70%	5% (najlepszy wynik)	Testowano pięć wariantów modelu. Brak zmienności prądu ładowania, rozładowania oraz głębokości rozładowania
[DB-1]	System rozmyty typu Mamdaniego	temperatura otoczenia głębokość rozładowania prąd rozładowania	15°C – 40°C 27% – 100% 1C – 3C	liczba cykli	0 – 2500	7,6%	
[56] (2017)	GPR	prąd ładowania temperatura głębokość rozładowania prąd rozładowania	1,5 A 25°C – 40°C (brak komory) 100% 0,2C	pojemność	100% – 70%	40%	Brak zmienności prądu ładowania, rozładowania oraz głębokości rozładowania. Model nie odwzorowuje dynamiki zmian procesu zużycia.
[59] (2019)	GPR	pojemność temperatura otoczenia głębokość rozładowania	dla 200 pierwszych cykli 35°C, 45°C 50%, 80%, 100%	pojemność	pozostały okres eksploatacji ogniwa (200 – 1500 cykli)	91,7% (najlepszy wynik)	Brak zmienności prądu ładowania oraz rozładowania, zrealizowano dwa przypadki testowe.
[60] (2022)	GPR	Zbiór sześciu parametrów reprezentujących energię ładowania i rozładowania	0 – 200 cykli	SOH	100% – 60%	8,3%	Brak zmienności temperatury, badania przeprowadzono jedynie dla dwóch wartości prądów ładowania i rozładowania.
[DB-2]	GPR	prąd ładowania temperatura otoczenia głębokość rozładowania prąd rozładowania dotychczasowy stan zużycia	0,62C – 1,34C 10°C – 40°C 16% – 100% 1C – 4C 100% – 80%	dSOH/dNeq	Cały okres eksploatacji ogniwa (SOH = 100% – SOH = 80%)	1,04%	Zaleta: błąd uzyskany w warunkach dynamicznie zmiennego obciążenia (generowanego losowo), model umożliwia identyfikację zmian dynamiki procesu zużycia.
[61] (2018)	Schemat zastępczy 2-rzędu	stan naładowania prąd rozładowania stan zużycia temperatura	100% – 0% 0,33C – 5C 100% – 85% 5°C – 45°C	MAE (maksymalna dostępna energia)	Pojedynczy cykl pracy	9,2 %	Model zweryfikowano tylko dla pojedynczego cyklu pracy podczas dynamicznie zmiennego obciążenia i temperatury.
[62] (2014)	Rozszerzony filtr Kalmana/ Filtr cząstek	napięcie prąd rozładowania temperatura	3,6 V – 2,0 V 0,5C – 4C -5°C – 45°C	SOE (stan dostępnej energii)	Pojedynczy cykl pracy	6,4% (filtr Kalmana), 1,83% (filtr cząstek)	Modele zweryfikowano dla dwóch przypadków testowych.
[63] (2017)	Fizykochemiczny	stan naładowania prąd rozładowania	100% – 0% 0,05C – 0,45C	SOE (stan dostępnej energii)	Pojedynczy cykl pracy	5%	Błędy predykcji dla początkowych cykli pracy osiągały wartości bliskie 20% we wszystkich przypadkach testowych.
[DB-3]	GPR	prąd ładowania średnia temperatura ogniwa głębokość rozładowania prąd rozładowania ekwiwalentna liczba cykli	0,5C – 1,33C 16,6°C – 62,1°C 70% – 100% 1C – 3C 0 – 1908	RUE _c	Cały okres eksploatacji ogniwa (SOH = 100% - SOH = 80%)	3,64%	Zaleta: model umożliwia identyfikację zmian dynamiki procesu zużycia.

3.4.5. Podsumowanie

W pracach badawczych, wykonanych przez Autora w ramach rozprawy doktorskiej, skupiono się na opracowaniu nowych i skuteczniejszych metod modelowania procesu zużycia ogniw litowo-niklowo-manganowo-kobaltowych pracujących w warunkach dynamicznie zmiennego obciążenia. Badania wyróżniały się tym, że były prowadzone dla takich parametrów pracy ogniw, które są zbliżone do warunków rzeczywistej eksploatacji i jednocześnie realizowane były w szerokim zakresie zmienności w całym okresie eksploatacji ogniw. Ze względu na stopień złożoności zagadnienia, Autor uwzględnił wiele parametrów pracy, w szczególności dotychczasowy stan zużycia ogniwa, co stanowi – w połączeniu z warunkami pracy realizowanych badań (zbliżonymi do rzeczywistych, w szerokim zakresie zmienności, w całym okresie eksploatacji) – nowatorskie podejście w stosunku do obecnych metod. Do osiągnięcia celu rozprawy doktorskiej zaplanowano i przeprowadzono bardzo czasochłonne pomiary eksperymentalne, które nieprzerwanie trwały przez 5 lat (przebadano 104 ogniw 18650 typu NMC).

Na podstawie przeprowadzonych pomiarów i analiz przedstawionych w rozprawie doktorskiej, sformułowano następujące wnioski:

- Ze względu na nieliniowy wpływ parametrów pracy ogniw na ich zużycie, stosowanie modeli uproszczonych (uwzględniających ograniczoną liczbę parametrów lub wąski zakres ich zmienności – np. powszechnie stosowane metody bazujące wyłącznie na zliczaniu ekwiwalentnych cykli) może prowadzić do znaczących błędów podczas wyznaczania parametrów związanych z trwałością, przede wszystkim w okresie długoterminowym, np. podczas całego okresu eksploatacji ogniwa.
- Największy wpływ na szybkość zużycia ogniwa ($dSOH/dNeq$) oraz relatywną energię użyteczną (RUE_c) mają następujące parametry: dotychczasowy stan zużycia, prąd rozładowania oraz temperatura (otoczenia lub ogniwa), o czym świadczą wysokie wartości współczynników korelacji (tabela 4) oraz wartości zakumulowanych efektów lokalnych ALE (rys. 17).
- Opracowany w pracy [DB-1] system rozmyty typu Mamdaniego jest skuteczną metodą modelowania procesu zużycia ogniw NMC.
- Zastąpienie często stosowanych funkcji wielomianowych lub równania Arrheniusa do modelowania wpływu temperatury przez funkcję typu Gaussowskiego (zależność 3) [DB-1] umożliwia poprawę dokładności wyznaczania liczby cykli w szerokim zakresie temperatur, w szczególności w niskich temperaturach.
- W zależności od warunków pracy ogniwa NMC w artykułach [DB-2] oraz [DB-3] zidentyfikowano różne wzorce przebiegu procesu zużycia (świadczące o zmianach szybkości zużycia) – rys. 10 oraz rys. 13.
- Opracowane przez Autora w pracach [DB-2, DB-3] wieloparametryczne modele mające zdolność uogólniania wiedzy (modele uczenia maszynowego) umożliwiają wyznaczanie, charakteryzującego się silną nieliniowością, stanu zużycia ogniwa podczas dynamicznie zmiennego obciążenia z wysoką dokładnością (dla modelu w pracy [DB-2] APE nie przekroczyło 5%, a w pracy [DB-3] za wyjątkiem kilku punktów testowych APE nie przekroczyło 7,5%). Istotnym osiągnięciem Autora jest znaczące udoskonalenie obecnie stosowanych metod poprzez uwzględnienie dodatkowego parametru modelu w postaci dotychczasowego stanu zużycia w całym okresie eksploatacji ogniwa.
- Na podstawie analiz przeprowadzonych w pracach [DB-2, DB-3] spośród testowanych modeli należących do grupy uczenia maszynowego z nadzorem, najniższym błędem predykcji

charakteryzuje się model regresji opartej na procesach Gaussowskich z funkcją jądrową typu Matern 3/2.

- Opracowane przez Autora metody modelowania procesu zużycia ogniw NMC mogą być zaimplementowane np. w celu optymalizacji pracy systemów zarządzania przepływem energii, a w konsekwencji wydłużenia żywotności akumulatorów, co jest obecnie jednym z kluczowych aspektów w przemyśle związanym z magazynowaniem energii.
- Atutem proponowanych metod badania i modelowania ogniw jest ich uniwersalność polegająca na możliwości ich zastosowania w ogniwach elektrochemicznych o innym składzie chemicznym.

Do najważniejszych osiągnięć naukowo-badawczych Autora zaprezentowanych w rozprawie doktorskiej zalicza się:

- zaplanowanie i przeprowadzenie serii eksperymentów polegających na badaniu ogniw NMC podczas ich cyklicznej degradacji [DB-1, DB-2, DB-3],
- zaproponowanie wykorzystania funkcji Gaussowskiej do celu odwzorowania wpływu temperatury otoczenia na liczbę cykli pracy ogniw [DB-1],
- opracowanie oraz zaimplementowanie rozmytego wieloparametrycznego modelu umożliwiającego wyznaczenie liczby cykli ogniwa w założonym okresie eksploatacji [DB-1],
- zaproponowanie nowego wskaźnika określającego szybkość zużycia ogniw ($dSOH/dNeq$), służącego do oceny wzorców ich degradacji [DB-2],
- identyfikacja trzech wzorców szybkości zużycia ogniw oraz relatywnej energii użytecznej w zależności od warunków ich pracy [DB-2, DB-3],
- opracowanie oraz implementacja wieloparametrycznego modelu predykcji szybkości zużycia i udowodnienie jego skuteczności zarówno podczas stałego jak i dynamicznie zmiennego (losowego) obciążenia [DB-2],
- opracowanie modelu służącego do predykcji relatywnej energii użytecznej, którą ogniwo może wymienić podczas pełnego cyklu pracy w całym okresie jego eksploatacji w różnych warunkach obciążeniowych i temperaturowych [DB-3],
- wyznaczanie ilościowego wpływu indywidualnych parametrów pracy cyklicznej oraz kombinacji ich par na dostępną energię użyteczną ogniw [DB-3].

Podsumowując, przeprowadzone w monotematycznym cyklu publikacji analizy oraz uzyskane wyniki dowodzą wysokiej efektywności przedstawionych autorskich metod modelowania procesu zużycia, z uwzględnieniem dynamicznie zmiennego obciążenia, i jednocześnie potwierdzają, że założony cel rozprawy doktorskiej został osiągnięty.

4. Podsumowanie działalności naukowo-badawczej – dane bibliometryczne

W tym rozdziale podsumowano dotychczasową działalność naukowo-badawczą Autora oraz aktualny stan cytowań (na dzień 12.05.2022 r.) w bazach Web of Science Core Collection, Scopus oraz Google Scholar.

4.1. Podsumowanie dotychczasowego dorobku publikacyjnego

Doktorant jest autorem 1 publikacji oraz współautorem 20 publikacji zamieszczonych w czasopiśmie lub materiałach konferencji międzynarodowych i krajowych. W tabeli 10 przedstawiono dane o cytowaniach artykułów naukowych w bazach naukowych: Web of Science, Scopus oraz Google Scholar. Z kolei w tabeli 11 zestawiono podsumowanie osiągnięć naukowych. Wykaz cytowań poszczególnych prac autorskich lub współautorskich umieszczono w załączniku 4.

Tabela 10. Informacje o liczbie cytowań w wybranych bazach naukowych.

Baza	Liczba indeksowanych artykułów	Całkowita liczba cytowań	Liczba cytowań bez autocytowań	Indeks Hirscha (<i>h-index</i>)
Web of Science Core Collection	10	43	28	4
Scopus	12	57	36	5
Google Scholar	18*	73	49	5

*praca [DB-3] została opublikowana w kwietniu 2022 r. w czasopiśmie znajdującym się na liście *JCR*, ale nie została jeszcze zaindeksowana.

Ze zbioru opublikowanych prac, 4 są indeksowane w bazie Journal Citation Reports. Sumaryczny *Impact Factor* Autora wynosi $IF = 15,92$. Łączna liczba punktów za artykuły naukowe obliczona zgodnie z wytycznymi *MEiN* wynosi 844 (710 obliczonych zgodnie z wykazem opublikowanym przez *MEiN* z dnia 01.12.2021 roku oraz 134 obliczonych zgodnie z wykazem opublikowanym przez *MNiSW* z dnia 25.01.2017 roku).

Tabela 11. Zestawienie osiągnięć naukowych.

Opublikowane prace naukowe			21
Czasopisma	Krajowe (<i>JCR</i>)	7 (1)	
	Międzynarodowe (<i>JCR</i>)	4 (3)	
Materiały konferencyjne	Krajowe	7	
	Międzynarodowe	3	
Członkostwo w radach recenzentów			1
Udział w konferencjach krajowych (prelegent)			4 (1)
Udział w konferencjach międzynarodowych (prelegent)			3 (1)
Recenzje artykułów dla czasopism	Zagraniczne (z bazy <i>JCR</i>)	13 (10)	
	Krajowe	4	
Staże			1

4.2. Pozostałe osiągnięcia naukowo-badawcze

Do pozostałych osiągnięć naukowo-badawczych niewchodzących w skład rozprawy doktorskiej należą prace związane głównie z tematyką modelowania funkcjonowania i zużycia ogniwo elektrochemicznych, a także innych typów magazynów energii:

Artykuły opublikowane w czasopismach naukowych:

- [DB-4] Kasprzyk L., Burzyński D., Lewandowska A., Pietracho R., Szymenderski J., Wenge Ch., „Modelowanie pracy ogniwo paliwowych w pojazdach wodorowych”. Przegląd Elektrotechniczny. 2021, R. 97, nr 12, s. 117-120. (70 pkt. MEiN).

W artykule przedstawiono rozwój badań nad ogniwoami paliwowymi oraz wykorzystanie ich w motoryzacji. Omówiono aspekty modelowania ogniwo paliwowych – ich zasadę działania, równanie Nernsta oraz najważniejsze parametry. Zaprezentowano aplikację komputerową służącą do symulacji pracy układu zasilania. Przeprowadzono analizę zachowania się ogniwo paliwowych oraz akumulatora w wodorowym autobusie miejskim. Uzyskane wyniki zaprezentowano w postaci wykresów i omówiono.

- [DB-5] Pietracho R., Wenge Ch., Balischewski S., Pio L., Komarnicki P., Kasprzyk L., Burzyński D., „Potential of Using Medium Electric Vehicle Fleet in a Commercial Enterprise Transport in Germany on the Basis of Real-World GPS Data”. Energies. 2021, vol. 14, no. 17, s.5327-1-5327-23. (140 pkt. MEiN; IF = 3,004).

W niniejszym artykule przedstawiono wpływ wykorzystania floty pojazdów elektrycznych zasilanych z akumulatorów (BEV) na rozkład obciążenia wybranego obiektu przemysłowego. Ponadto w pracy przedstawiono wyniki symulacji pozwalające na określenie potencjału wykorzystania floty oraz zużycia energii przez pojazdy elektryczne na podstawie rzeczywistych danych, reprezentujących procesy związane z codziennym użytkowaniem pojazdów elektrycznych. Na tej podstawie możliwe jest określenie skutków i zmienności obciążenia sieci elektroenergetycznej w przypadku wymiany floty pojazdów spalinowych wykorzystywanych obecnie na pojazdy elektryczne do świadczenia usług transportowych. Przedstawiono trzy modele, umożliwiające obliczenie zmian zapotrzebowania na energię dla każdego ze scenariuszy. Na koniec określono i przedyskutowano potencjał wykorzystania floty pojazdów elektrycznych do zwiększenia funkcjonalności nowoczesnego obiektu przemysłowego. Na podstawie danych dla przyjętych scenariuszy stwierdzono, że elektryfikacja transportu może zwiększyć zapotrzebowanie na energię o 40,9% w przypadku pojedynczych przedsiębiorstw.

- [DB-6] Burzyński D., Kasprzyk L., „Analysis of the potential use of lithium-ion energy storage in the home charging station for electric cars”. IOP Conference Series: Earth and Environment Science. 2019, vol. 214, s. 012077-1-012077-11. (5 pkt. MNiSW).

W artykule poruszono problemy związane z magazynowaniem energii elektrycznej w stacjach ładowania pojazdów elektrycznych na przykładzie domowej stacji ładowania pojazdów, współpracującej z instalacją fotowoltaiczną. Przedstawione zagadnienia obejmują charakterystykę stacji ładowania pojazdów, problematykę konwersji energii słonecznej na elektryczną oraz metodykę wyznaczania energii możliwej do pozyskania z instalacji fotowoltaicznych. Ponadto omówiono metody modelowania pracy ogniwo

litowo-jonowych z uwzględnieniem ich żywotności, a także przedstawiono przykładową symulację zachowania elektrochemicznego magazynu energii współpracującego ze stacją ładowania pojazdów elektrycznych i instalacją fotowoltaiczną. We wnioskach zwrócono uwagę na aspekt żywotności magazynów energii w odniesieniu do zasadności ich zastosowania jako magazynów energii dla stacji ładowania pojazdów elektrycznych współpracujących z odnawialnymi źródłami energii (OZE).

- [DB-7] Kasprzyk L., Burzyński D., Domeracka A., „Modelowanie pracy i trwałości akumulatorów litowo-jonowych w pojazdach elektrycznych”. Przegląd Elektrotechniczny. 2018, R. 94, nr 12, s. 158-161. (14 pkt. MNiSW).

W artykule przedstawiono problematykę modelowania pracy oraz zużycia akumulatorów w pojazdach elektrycznych. Omówiono podstawowe metody modelowania pracy akumulatorów elektrochemicznych oraz szacowania ich zużycia podczas rozładowania zmiennego w czasie. Zaprezentowano symulację, w której analizowano zachowanie się akumulatorów LiFeMnPO₄ podczas obciążenia charakterystycznego dla pojazdów elektrycznych. Uzyskane wyniki przedstawiono i skomentowano.

- [DB-8] Burzyński D., Kasprzyk L., „Modelowanie pracy akumulatorów kwasowo-ołowiowych w stanach dynamicznych”. Poznan University of Technology Academic Journals. Electrical Engineering. 2017, Issue 92, s. 37-46. (9 pkt. MNiSW).

W pracy przedstawiono aspekty związane z modelowaniem elektrochemicznych magazynów energii elektrycznej na przykładzie akumulatorów kwasowo-ołowiowych. Omówiono zasobniki energii najczęściej stosowane obecnie w technice i zestawiono ich podstawowe parametry techniczne. Zaprezentowano szczegółowy model matematyczny ogniwa akumulatora kwasowo-ołowiowego oraz jego parametry. Przedstawiono wzory empiryczne opisujące poszczególne parametry schematu zastępczego ogniwa. Szczególny nacisk położono na problematykę doboru modelu oraz konieczności uwzględniania zjawisk chemicznych (powiązanych z rodzajem modelu) do rozważanego zagadnienia.

- [DB-9] Burzyński D., Kasprzyk L., „Wybrane metody modelowania pracy ogniw elektrochemicznych”. Przegląd Elektrotechniczny. 2017. R. 93, nr 12, s. 75-78. (14 pkt. MNiSW).

W artykule przedstawiono dwie techniki modelowania pracy ogniw elektrochemicznych – model elektrochemiczny oraz obwodowy. W modelu elektrochemicznym opisano procesy związane z dyfuzją oraz przeniesieniem nośników ładunku zachodzące w elektrolicie oraz na elektrodach ogniwa. Zaprezentowano przykładowy schemat zastępczy ogniwa oraz omówiono techniki estymacji parametrów modelu. W podsumowaniu skomentowano zalety i wady przedstawionych metod modelowania.

- [DB-10] Kasprzyk L., Bednarek K., Burzyński D., „Symulacja pracy akumulatorów kwasowo-ołowiowych”. Przegląd Elektrotechniczny. 2016, R. 92, nr 12, s. 61-64. (14 pkt. MNiSW).

W artykule zaprezentowano zagadnienia związane z modelowaniem pracy zasobników energii elektrycznej na przykładzie elektrochemicznych źródeł energii, jakimi są

akumulatory kwasowo-ołowiowe. Przedstawiono uzasadnienie konieczności analizy pracy zasobników energii, szczegółowo omówiono model matematyczny ogniwa kwasowo-ołowiowego oraz zaprezentowano przykładową analizę zachowania się takiego ogniwa podczas jazdy samochodem elektrycznym.

- [DB-11] Burzyński D., Kasprzyk L., „Use of LabVIEW software for electromagnetic calculation of induction motors”. Computer Applications in Electrical Engineering. 2015, vol. 13, s. 364-375. (6 pkt. MNiSW).

W artykule przedstawiono możliwości wykorzystania oprogramowania LabVIEW do obliczeń elektromagnetycznych silników indukcyjnych. Podano również najważniejsze zależności opisujące parametry elektromagnetyczne dla rozpatrywanych silników wraz z zastosowanym algorytmem obliczeniowym. Opracowano i szczegółowo opisano aplikację wykorzystywaną do obliczeń elektromagnetycznych silników indukcyjnych z wirnikiem nawijanym z rowkami w kształcie kropli. Na podstawie przedstawionego algorytmu zaimplementowanego w środowisku LabVIEW wyznaczono parametry obwodu magnetycznego dla silnika trójfazowego o mocy znamionowej 2,2 kW.

Materiały konferencyjne:

- [DB-12] Kasprzyk L., Burzyński D., Lewandowska A., Pietracho R., „Modelowanie pracy ogniwa paliwowych w pojazdach wodorowych”. XXX Sympozjum Środowiskowe PTZE: Zastosowania elektromagnetyzmu we współczesnej inżynierii i medycynie – Warszawa, Polska: Polskie Towarzystwo Zastosowań Elektromagnetyzmu. 2021, s. 133-135. (5 pkt. MEiN).

- [DB-13] Pietracho R., Kasprzyk L., Burzyński D., „Electrical propulsion systems in vehicles – an overview of solutions”. Applications of Electromagnetics in Modern Engineering and Medicine (PTZE 2019): IEEE. 2019, s. 130-135. (20 pkt. MNiSW).

W artykule opisano nowoczesne technologie stosowane w przemyśle motoryzacyjnym w zakresie rozwoju układów napędowych pojazdów. Przedstawiono przykłady zastosowania hybrydowych układów napędowych dla trzech grup pojazdów: lądowych, morskich

i powietrznych. Opisano koncepcje rozwiązań technicznych i wyszczególniono potencjalne korzyści wynikające z modyfikacji tradycyjnych układów spalinowych na elektryczne.

- [DB-14] Burzyński D., Kasprzyk L., „The operation and capacity fade modelling of the lithium-ion cell for electric vehicles”. E3S Web of Conferences. 2019, vol. 108, s. 01017-1-01017-10. (5 pkt. MNiSW).

W artykule poruszono zagadnienia związane z modelowaniem pracy i utraty pojemności ogniwa litowo-jonowego. Obejmuje on prezentację modelu elektrochemicznego ogniwa, w którym omówiono zjawisko dyfuzji i przenoszenia ładunku na elektrodach i w elektrolicie. Przedstawiono model obwodowy ogniwa przeznaczony do analizy jego zachowania w warunkach dynamicznie zmiennego obciążenia. Scharakteryzowano kluczowe procesy starzeniowe zachodzące podczas eksploatacji ogniwa oraz omówiono ich wpływ na zużycie ogniwa. Opracowano model procesu zużycia ogniwa litowo-niklowo-

manganowo-kobaltowego. Parametry modelu zależą od temperatury otoczenia, wartości prądu obciążenia oraz wartości średniego prądu ładowania. Wyniki modelu zostały zweryfikowane z pomiarami laboratoryjnymi.

- [DB-15] Burzyński D., Głuchy D., Godek M., „Wpływ temperatury na parametry procesu ładowania z wykorzystaniem technologii Quick Charge oraz trwałość ogniw litowo-jonowych”. *Poznan University of Technology Academic Journals. Electrical Engineering*. 2018, Issue 95, s. 309-320. (9 pkt. MNiSW).

W pracy podjęto tematykę wpływu temperatury na parametry procesu ładowania i trwałość ogniw litowo-jonowych ładowanych z wykorzystaniem technologii Quick Charge. Opisano stosowane obecnie techniki szybkiego ładowania oraz procesy starzeniowe zachodzące w ogniwach litowo-jonowych. Przeprowadzono pomiary parametrów ogniwa w trakcie procesu ładowania dla dwóch różnych temperatur. W pracy przedstawiono również wnioski dotyczące przeprowadzonych badań.

- [DB-16] Burzyński D., Kasprzyk L., „Modelling and simulation of lead-acid battery pack powering electric vehicle”. *E3S Web of Conferences*. 2017, vol. 14. (15 pkt. MNiSW).

W artykule przedstawiono wybrane aspekty metod modelowania magazynów energii na przykładzie akumulatora kwasowo-ołowiowego do zasilania pojazdu elektrycznego. Omówiono najczęściej stosowane magazyny energii, ze szczególnym uwzględnieniem trudności w ich właściwym doborze do urządzeń mobilnych. Przedstawiono również model matematyczny akumulatora kwasowo-ołowiowego oraz zależności opisujące jego poszczególne parametry. Wybrany magazyn energii poddano szczegółowej analizie pod względem parametrów elektrycznych i cieplnych podczas zasilania pojazdu elektrycznego w standardowym cyklu jazdy na terenie miejskim. Symulację przeprowadzono w środowisku Matlab Simulink.

- [DB-17] Kasprzyk L., Burzyński D., „Techniki modelowania ogniw elektrochemicznych stosowanych w pojazdach elektrycznych”. *XXVII Sympozjum Środowiskowe PTZE: Zastosowania Elektromagnetyzmu w Nowoczesnych Technikach i Medycynie – Mierzęcin, Poland*. 2017, s. 113-115.

- [DB-18] Kasprzyk L., Burzyński D., „Wyznaczanie parametrów schematu zastępczego akumulatorów elektrochemicznych z wykorzystaniem spektroskopii impedancyjnej”. *IC-SPETO 2017: XL Międzynarodowa konferencja z podstaw elektrotechniki i teorii obwodów*, Gliwice-Ustroń, 17.05.2017 – Gliwice, Polska: Politechnika Śląska, Wydział Elektryczny, Instytut Elektrotechniki i Informatyki. 2017, s. 71-71. (20 pkt. MNiSW).

W artykule przedstawiono metody wyznaczania parametrów obwodów zastępczych elektrochemicznych magazynów energii na podstawie danych pomiarowych uzyskanych techniką elektrochemicznej spektroskopii impedancyjnej. Omówiono zagadnienia związane z modelowaniem procesów elektrochemicznych, zachodzących w baterii litowo-jonowej, z wykorzystaniem obwodów elektrycznych.

- [DB-19] Kasprzyk L., Burzyński D., „Modelowanie zachowania się akumulatora kwasowo-ołowiowego podczas jazdy samochodu elektrycznego z wykorzystaniem środowiska

MATLAB". Poznan University of Technology Academic Journals. Electrical Engineering. 2016, Issue 86, s. 255-265. (9 pkt. MNiSW).

W pracy omówiono problematykę modelowania zachowania się zasobników energii w pojazdach elektrycznych na przykładzie akumulatora kwasowo-ołowiowego. Przedstawiono zagadnienia magazynowania energii elektrycznej w obiektach mobilnych, zwracając uwagę na problematykę doboru magazynów do odbiorników charakteryzujących się dużą dynamiką zmienności pobieranej mocy. Ponadto zaprezentowano szczegółowy model akumulatora kwasowo-ołowiowego, umożliwiającą precyzyjną symulację jego pracy, a także zależności opisujące parametry modelu. W pracy przedstawiono również wyniki symulacji pracy akumulatora wyznaczone przy użyciu środowiska MATLAB Simulink.

[DB-20] Kasprzyk L., Bednarek K., Burzyński D., „Symulacja pracy akumulatora kwasowo-ołowiowego zasilającego pojazd elektryczny”. 6th International Symposium on Applied Electromagnetics SAEM'16 & XXVI Sympozjum Środowiskowe PTZE Zastosowania Elektromagnetyzmu w Nowoczesnych Technikach i Medycynie, Wrocław 26-29 June 2016 – Warszawa, Polska: Polskie Towarzystwo Zastosowań Elektromagnetyzmu. 2016, s. 127-129.

[DB-21] Burzyński D., Kasprzyk L., „Aplikacja napisana w środowisku LABVIEW służąca do wyznaczania współczynnika uzwojenia maszyny indukcyjnej”. Poznan University of Technology Academic Journals. Electrical Engineering. 2015, Issue 83, s. 107-112. (9 pkt. MNiSW).

W artykule zaprezentowano aplikację służącą do wyznaczania współczynnika uzwojenia maszyny indukcyjnej, stworzoną w środowisku LabVIEW. Przedstawiono zależności opisujące współczynnik uzwojenia oraz omówiono szczegółowe algorytmy wyznaczania współczynnika uzwojenia trójfazowej maszyny indukcyjnej dla uzwojeń o całkowitej i ułamkowej liczbie żłobków przypadającej na każdy biegun i pasmo. Na podstawie przedstawionych algorytmów zaimplementowanych w środowisku LabVIEW wyznaczono przykładowe współczynniki uzwojeń dla trzech wybranych rozwiązań konstrukcyjnych silników indukcyjnych.

4.3. Pozostała aktywność naukowa

Autor wykazuje się aktywnością naukową realizowaną w różnych instytucjach naukowych, również zagranicznych. Autor jest członkiem rady recenzentów czasopisma *Electronics* będącego na liście JCR oraz wielokrotnie recenzował prace dla czasopism:

- *Energies* (4),
- *Electronics* (3),
- *Batteries* (1),
- *Sustainability* (1),
- *World Electric Vehicle Journal* (1),
- *E3S. Web of Conferences* (3),
- *Poznan University of Technology Academic Journals* (4).

Dwukrotnie brał udział w przygotowaniu wniosku do NCBiR w ramach programu INNOMOTO o dofinansowanie projektu na budowę pojazdu elektrycznego.

Autor brał wielokrotnie udział w konferencjach krajowych („Zastosowanie Komputerów w Elektrotechnice” w latach 2015–2018) oraz międzynarodowych („Energy and Fuels” w latach 2016, 2018 oraz „International Conference on the Sustainable Energy and Environmental Development” w roku 2017).

5. Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę

W roku 2019 Autor był opiekunem merytorycznym projektu w ramach Szkoły Letniej dla studentów z Indii pod nazwą „Mikroprocesorowe sterowanie przepływem prądu między hybrydowym magazynem energii a odbiornikiem”. W ramach aktywności dydaktycznej Autor od wielu lat jest opiekunem i rozwija laboratorium Magazynów Energii znajdujące się w Instytucie Elektrotechniki i Elektroniki Przemysłowej. Ponadto opracował stanowiska laboratoryjne oraz materiały dydaktyczne i instrukcje ćwiczeniowe na potrzeby realizacji zajęć laboratoryjnych z przedmiotu *Magazyny energii i systemy hybrydowe* realizowanego na kierunku *energetyka*. Brał aktywny udział w kole naukowym PUT Solar Dynamics podczas badań związanych z akumulatorami elektrochemicznymi. Kilukrotnie był koordynatorem praktyk studenckich.

Autor prowadzi następujące zajęcia dydaktyczne na studiach stacjonarnych oraz niestacjonarnych I i II stopnia, a także zajęcia w ramach programu *Erasmus*:

Studia stacjonarne I stopnia:

- Teoria obwodów – ćwiczenia
- Technika mikroprocesorowa – laboratorium
- Komputeryzacja projektowania w elektrotechnice – laboratorium
- Programowanie obiektowe – laboratorium
- Elektrotechnika i elektronika – laboratorium
- Magazyny energii i systemy hybrydowe – laboratorium

Studia stacjonarne II stopnia:

- Technika mikroprocesorowa – laboratorium
- Technika mikroprocesorowa – projekt
- Wybrane zagadnienia techniki mikroprocesorowej – laboratorium
- Wybrane zagadnienia elektrotechniki – ćwiczenia
- Programowanie obiektowe w elektrotechnice – wykład
- Nowoczesne systemy magazynowania i przetwarzania energii – wykład

Studia niestacjonarne I stopnia:

- Komputeryzacja projektowania w elektrotechnice – laboratorium
- Teoria obwodów – ćwiczenia

Studia niestacjonarne II stopnia:

- Programowanie obiektowe i bazy danych – laboratorium
- Programowanie obiektowe w elektrotechnice – wykład

Erasmus:

- Object-oriented programming in electrical engineering – wykład
- Object-oriented programming in electrical engineering – laboratorium
- Electromobility and energy storage – laboratorium

6. Inne informacje ważne z punktu widzenia kariery zawodowej

W okresie od 04.01.2021 do 31.03.2021 Autor odbył staż w firmie Messor Sp. z o.o., podczas którego brał udział w badaniach akumulatorów litowo-jonowych oraz pracach związanych z opracowaniem funkcjonalnego modelu akumulatora, służącego do zasilania pojazdu elektrycznego typu UTV. Od początku pracy naukowej autor uzyskiwał środki na finansowanie działalności naukowej w ramach Działalności Statutowej Młoda Kadra, Działalności Naukowej Młoda Kadra oraz Badania Naukowe finansowane z subwencji badawczej (SBAD):

- Badania Statutowe Młoda Kadra (2016) – „Badanie wybranych parametrów elektrycznych akumulatorów kwasowo-ołowiowych” – **kierownik projektu**
- Badania Statutowe Młoda Kadra (2017) – „Badanie i analiza wybranych parametrów elektrycznych akumulatorów litowo-jonowych oraz superkondensatorów” – wykonawca
- Badania Statutowe Młoda Kadra (2018) – „Badania i analiza układu akumulator-superkondensator współpracującego z odnawialnymi źródłami energii” – **kierownik projektu**
- Działalność Naukowa Młoda Kadra (2019) – „Badania i analiza trwałości ogniwo litowo-jonowych” – wykonawca
- Działalność Naukowa Młoda Kadra (2020) – „Modelowanie procesu zużycia ogniwa litowo-jonowego podczas stałych warunków obciążenia” – wykonawca
- Działalność Naukowa Młoda Kadra (2021) – „Analiza uzysków energii elektrycznej z paneli bifacjalnych w różnych konfiguracjach montażowych” – wykonawca
- Subwencja Badawcza (SBAD) (2022) – „Generacja, magazynowanie i przetwarzanie energii z wykorzystaniem wybranych układów elektrycznych” – wykonawca

Wykaz literatury

- [1] EEA, *Monitoring carbon dioxide emissions from passenger cars and vans in 2014*, no. 19. 2015.
- [2] U.S. Department of Energy, “Energy Storage Grand Challenge Energy Storage Market Report 2020,” *U.S. Dep. Energy*, vol. Technical, no. December, p. 65, 2020.
- [3] K. Edström *et al.*, “BATTERY 2030+ Roadmap,” p. 83, 2020.
- [4] N. Omar *et al.*, “Lithium iron phosphate based battery - Assessment of the aging parameters and development of cycle life model,” *Appl. Energy*, vol. 113, pp. 1575–1585, 2014.
- [5] B. Xu, A. Oudalov, A. Ulbig, G. Andersson, and D. S. Kirschen, “Modeling of lithium-ion battery degradation for cell life assessment,” *IEEE Trans. Smart Grid*, vol. 9, no. 2, pp. 1131–1140, 2018.
- [6] R. Xiong, J. Cao, Q. Yu, H. He, and F. Sun, “Critical Review on the Battery State of Charge Estimation Methods for Electric Vehicles,” *IEEE Access*, vol. 6, pp. 1832–1843, 2017.
- [7] M.-F. Ng, J. Zhao, Q. Yan, G. J. Conduit, and Z. W. Seh, “Predicting the state of charge and health of batteries using data-driven machine learning,” *Nat. Mach. Intell.*, vol. 2, no. 3, pp. 161–170, 2020.
- [8] M. Berecibar, I. Gandiaga, I. Villarreal, N. Omar, J. Van Mierlo, and P. Van Den Bossche, “Critical review of state of health estimation methods of Li-ion batteries for real applications,” *Renew. Sustain. Energy Rev.*, vol. 56, pp. 572–587, 2016.
- [9] R. Xiong, Y. Zhang, J. Wang, H. He, S. Peng, and M. Pecht, “Lithium-Ion Battery Health Prognosis Based on a Real Battery Management System Used in Electric Vehicles,” *IEEE Trans. Veh. Technol.*, vol. 68, no. 5, pp. 4110–4121, 2019.
- [10] T. Liu, L. Cheng, Z. Pan, and Q. Sun, “Cycle life prediction of lithium-ion cells under complex temperature profiles,” *Eksploatacja i Niezawodn. - Maint. Reliab.*, vol. 18, no. 1, pp. 25–31, 2016.
- [11] Y. Gao, J. Jiang, C. Zhang, W. Zhang, Z. Ma, and Y. Jiang, “Lithium-ion battery aging mechanisms and life model under different charging stresses,” *J. Power Sources*, vol. 356, pp. 103–114, 2017.
- [12] X. Han, M. Ouyang, L. Lu, and J. Li, “Cycle life of commercial lithium-ion batteries with lithium titanium oxide anodes in electric vehicles,” *Energies*, vol. 7, no. 8, pp. 4895–4909, 2014.
- [13] L. De Sutter *et al.*, “Comprehensive Aging Analysis of Volumetric Constrained Lithium-Ion Pouch Cells with High Concentration Silicon-Alloy Anodes,” *Energies*, vol. 11, no. 11, 2018.
- [14] G. Suri and S. Onori, “A control-oriented cycle-life model for hybrid electric vehicle lithium-ion batteries,” *Energy*, vol. 96, pp. 644–653, 2016.
- [15] J. de Hoog *et al.*, “Combined cycling and calendar capacity fade modeling of a Nickel-Manganese-Cobalt Oxide Cell with real-life profile validation,” *Appl. Energy*, vol. 200, pp. 47–61, 2017.
- [16] J. Schmalstieg, S. Käbitz, M. Ecker, and D. U. Sauer, “A holistic aging model for Li(NiMnCo)O₂ based 18650 lithium-ion batteries,” *J. Power Sources*, vol. 257, pp. 325–334, 2014.
- [17] C. Dudézert, Y. Reynier, J. M. Duffault, and S. Franger, “Fatigue damage approach applied to Li-ion batteries ageing characterization,” *Mater. Sci. Eng. B Solid-State Mater. Adv. Technol.*, vol. 213, pp. 177–189, 2016.
- [18] V. J. Ovejas and A. Cuadras, “Effects of cycling on lithium-ion battery hysteresis and overvoltage,” *Sci. Rep.*, vol. 9, no. 1, pp. 1–9, 2019.
- [19] M. Naumann, F. Spingler, and A. Jossen, “Analysis and modeling of cycle aging of a commercial LiFePO₄/graphite cell,” *J. Power Sources*, vol. 451, no. December 2019, p. 227666, 2020.
- [20] Y. Zhang, Q. Tang, Y. Zhang, J. Wang, U. Stimming, and A. A. Lee, “Identifying degradation patterns of lithium ion batteries from impedance spectroscopy using machine learning,” *Nat. Commun.*, vol. 11, no. 1, pp. 6–11, 2020.
- [21] S. F. Schuster *et al.*, “Nonlinear aging characteristics of lithium-ion cells under different operational conditions,” *J. Energy Storage*, vol. 1, no. 1, pp. 44–53, 2015.

- [22] C. R. Birkl, M. R. Roberts, E. McTurk, P. G. Bruce, and D. A. Howey, "Degradation diagnostics for lithium ion cells," *J. Power Sources*, vol. 341, pp. 373–386, 2017.
- [23] J. Vetter *et al.*, "Ageing mechanisms in lithium-ion batteries," *J. Power Sources*, vol. 147, no. 1–2, pp. 269–281, 2005.
- [24] M. Broussely *et al.*, "Main aging mechanisms in Li ion batteries," *J. Power Sources*, vol. 146, no. 1–2, pp. 90–96, 2005.
- [25] A. Wang, S. Kadam, H. Li, S. Shi, and Y. Qi, "Review on modeling of the anode solid electrolyte interphase (SEI) for lithium-ion batteries," *npj Comput. Mater.*, vol. 4, no. 1, 2018.
- [26] V. A. Sethuraman, L. J. Hardwick, V. Srinivasan, and R. Kostecki, "Surface structural disordering in graphite upon lithium intercalation/deintercalation," *J. Power Sources*, vol. 195, no. 11, pp. 3655–3660, 2010.
- [27] L. Tao, J. Ma, Y. Cheng, A. Noktehdan, J. Chong, and C. Lu, "A review of stochastic battery models and health management," *Renew. Sustain. Energy Rev.*, vol. 80, no. February 2018, pp. 716–732, 2017.
- [28] M. C. Schulze and N. R. Neale, "Half-Cell Cumulative Efficiency Forecasts Full-Cell Capacity Retention in Lithium-Ion Batteries," *ACS Energy Lett.*, vol. 6, no. 3, pp. 1082–1086, 2021.
- [29] J. Guo, Z. Li, and M. Pecht, "A Bayesian approach for Li-Ion battery capacity fade modeling and cycles to failure prognostics," *J. Power Sources*, vol. 281, pp. 173–184, 2015.
- [30] A. Nuhic, T. Terzimehic, T. Soczka-Guth, M. Buchholz, and K. Dietmayer, "Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods," *J. Power Sources*, vol. 239, pp. 680–688, 2013.
- [31] D. Yang, Y. Wang, R. Pan, R. Chen, and Z. Chen, "A Neural Network Based State-of-Health Estimation of Lithium-ion Battery in Electric Vehicles," *Energy Procedia*, vol. 105, pp. 2059–2064, 2017.
- [32] A. Barré, F. Suard, M. Gérard, M. Montaru, and D. Riu, "Statistical analysis for understanding and predicting battery degradations in real-life electric vehicle use," *J. Power Sources*, vol. 245, pp. 846–856, 2014.
- [33] J. Olmos, I. Gandiaga, A. Saez-de-Ibarra, X. Larrea, T. Nieva, and I. Aizpuru, "Modelling the cycling degradation of Li-ion batteries: Chemistry influenced stress factors," *J. Energy Storage*, vol. 40, no. May, p. 102765, 2021.
- [34] K. Liu, X. Tang, R. Teodorescu, F. Gao, and J. Meng, "Future Ageing Trajectory Prediction for Lithium-ion Battery Considering the Knee Point Effect," *IEEE Trans. Energy Convers.*, vol. 8969, no. c, pp. 1–10, 2021.
- [35] X. Han, M. Ouyang, L. Lu, and J. Li, "A comparative study of commercial lithium ion battery cycle life in electric vehicle: Capacity loss estimation," *J. Power Sources*, vol. 268, pp. 658–669, 2014.
- [36] M. Safari, M. Morcrette, A. Teyssot, and C. Delacourt, "Multimodal Physics-Based Aging Model for Life Prediction of Li-Ion Batteries," *J. Electrochem. Soc.*, vol. 156, no. 3, p. A145, 2009.
- [37] M. Ecker *et al.*, "Development of a lifetime prediction model for lithium-ion batteries based on extended accelerated aging test data," *J. Power Sources*, vol. 215, pp. 248–257, 2012.
- [38] G. Kaneko *et al.*, "Analysis of degradation mechanism of lithium iron phosphate battery," *World Electr. Veh. J.*, vol. 6, no. 3, pp. 555–561, 2013.
- [39] K. H. Tseng, J. W. Liang, W. Chang, and S. C. Huang, "Regression models using fully discharged voltage and internal resistance for state of health estimation of lithium-ion batteries," *Energies*, vol. 8, no. 4, pp. 2889–2907, 2015.
- [40] X. Li, J. Miao, and J. Ye, "Lithium-ion battery remaining useful life prediction based on grey support vector machines," *Adv. Mech. Eng.*, vol. 7, no. 12, pp. 1–8, 2015.
- [41] Y. Li *et al.*, "Data-driven health estimation and lifetime prediction of lithium-ion batteries: A review," *Renew. Sustain. Energy Rev.*, vol. 113, no. June, 2019.
- [42] K. Liu, Y. Shang, Q. Ouyang, and W. D. Widanage, "A Data-Driven Approach with Uncertainty Quantification for Predicting Future Capacities and Remaining Useful Life of Lithium-ion Battery," *IEEE Trans. Ind. Electron.*, vol. 68, no. 4, pp. 3170–3180, 2021.

- [43] S. A. Hasib *et al.*, “A Comprehensive Review of Available Battery Datasets, RUL Prediction Approaches, and Advanced Battery Management,” *IEEE Access*, vol. 9, pp. 86166–86193, 2021.
- [44] X. Hu, J. Jiang, D. Cao, and B. Egardt, “Battery health prognosis for electric vehicles using sample entropy and sparse Bayesian predictive modeling,” *IEEE Trans. Ind. Electron.*, vol. 63, no. 4, pp. 2645–2656, 2016.
- [45] R. R. Richardson, C. R. Birkl, M. A. Osborne, and D. A. Howey, “Gaussian Process Regression for in Situ Capacity Estimation of Lithium-Ion Batteries,” *IEEE Trans. Ind. Informatics*, vol. 15, no. 1, pp. 127–138, 2019.
- [46] K. Liu, Y. Li, X. Hu, M. Lucu, and W. D. Widanage, “Gaussian Process Regression with Automatic Relevance Determination Kernel for Calendar Aging Prediction of Lithium-Ion Batteries,” *IEEE Trans. Ind. Informatics*, vol. 16, no. 6, pp. 3767–3777, 2020.
- [47] P. Tagade *et al.*, “Deep Gaussian process regression for lithium-ion battery health prognosis and degradation mode diagnosis,” *J. Power Sources*, vol. 445, no. October 2019, p. 227281, 2020.
- [48] C. Vidal, P. Malysz, P. Kollmeyer, and A. Emadi, “Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art,” *IEEE Access*, vol. 8, pp. 52796–52814, 2020.
- [49] B. Saha, K. Goebel, S. Poll, and J. Christophersen, “Prognostics methods for battery health monitoring using a Bayesian framework,” *IEEE Trans. Instrum. Meas.*, vol. 58, no. 2, pp. 291–296, 2009.
- [50] K. A. Severson *et al.*, “Data-driven prediction of battery cycle life before capacity degradation,” *Nat. Energy*, vol. 4, no. 5, pp. 383–391, 2019.
- [51] S. S. Mansouri, P. Karvelis, G. Georgoulas, and G. Nikolakopoulos, “Remaining Useful Battery Life Prediction for UAVs based on Machine Learning,” *IFAC-PapersOnLine*, vol. 50, no. 1, pp. 4727–4732, 2017.
- [52] L. Ren, L. Zhao, S. Hong, S. Zhao, H. Wang, and L. Zhang, “Remaining Useful Life Prediction for Lithium-Ion Battery: A Deep Learning Approach,” *IEEE Access*, vol. 6, pp. 50587–50598, 2018.
- [53] P. Khumprom and N. Yodo, “A data-driven predictive prognostic model for lithium-ion batteries based on a deep learning algorithm,” *Energies*, vol. 12, no. 4, pp. 1–21, 2019.
- [54] J. Wu, Y. Wang, X. Zhang, and Z. Chen, “A novel state of health estimation method of Li-ion battery using group method of data handling,” *J. Power Sources*, vol. 327, pp. 457–464, 2016.
- [55] M. Bercibar *et al.*, “Online state of health estimation on NMC cells based on predictive analytics,” *J. Power Sources*, vol. 320, pp. 239–250, 2016.
- [56] R. R. Richardson, M. A. Osborne, and D. A. Howey, “Gaussian process regression for forecasting battery state of health,” *J. Power Sources*, vol. 357, pp. 209–219, 2017.
- [57] G. O. Sahinoglu, M. Pajovic, Z. Sahinoglu, Y. Wang, P. V. Orlik, and T. Wada, “Battery State-of-Charge Estimation Based on Regular/Recurrent Gaussian Process Regression,” *IEEE Trans. Ind. Electron.*, vol. 65, no. 5, pp. 4311–4321, 2018.
- [58] Karta katalogowa ogniwa Samsung ICR 18650-26H. Version No. 1.0
- [59] K. Liu, X. Hu, Z. Wei, Y. Li, and Y. Jiang, “Modified Gaussian Process Regression Models for Cyclic Capacity Prediction of Lithium-Ion Batteries,” *IEEE Trans. Transp. Electrification*, vol. 5, no. 4, pp. 1225–1236, 2019.
- [60] L. Cai, J. Lin, and X. Liao, “An estimation model for state of health of lithium-ion batteries using energy-based features,” *J. Energy Storage*, vol. 46, no. November 2021, p. 103846, 2022.
- [61] K. Li, F. Wei, K. J. Tseng, and B. H. Soong, “A Practical Lithium-Ion Battery Model for State of Energy and Voltage Responses Prediction Incorporating Temperature and Ageing Effects,” *IEEE Trans. Ind. Electron.*, vol. 65, no. 8, pp. 6696–6708, 2018.
- [62] Y. Wang, C. Zhang, and Z. Chen, “A method for joint estimation of state-of-charge and available energy of LiFePO₄ batteries,” *Appl. Energy*, vol. 135, pp. 81–87, 2014.

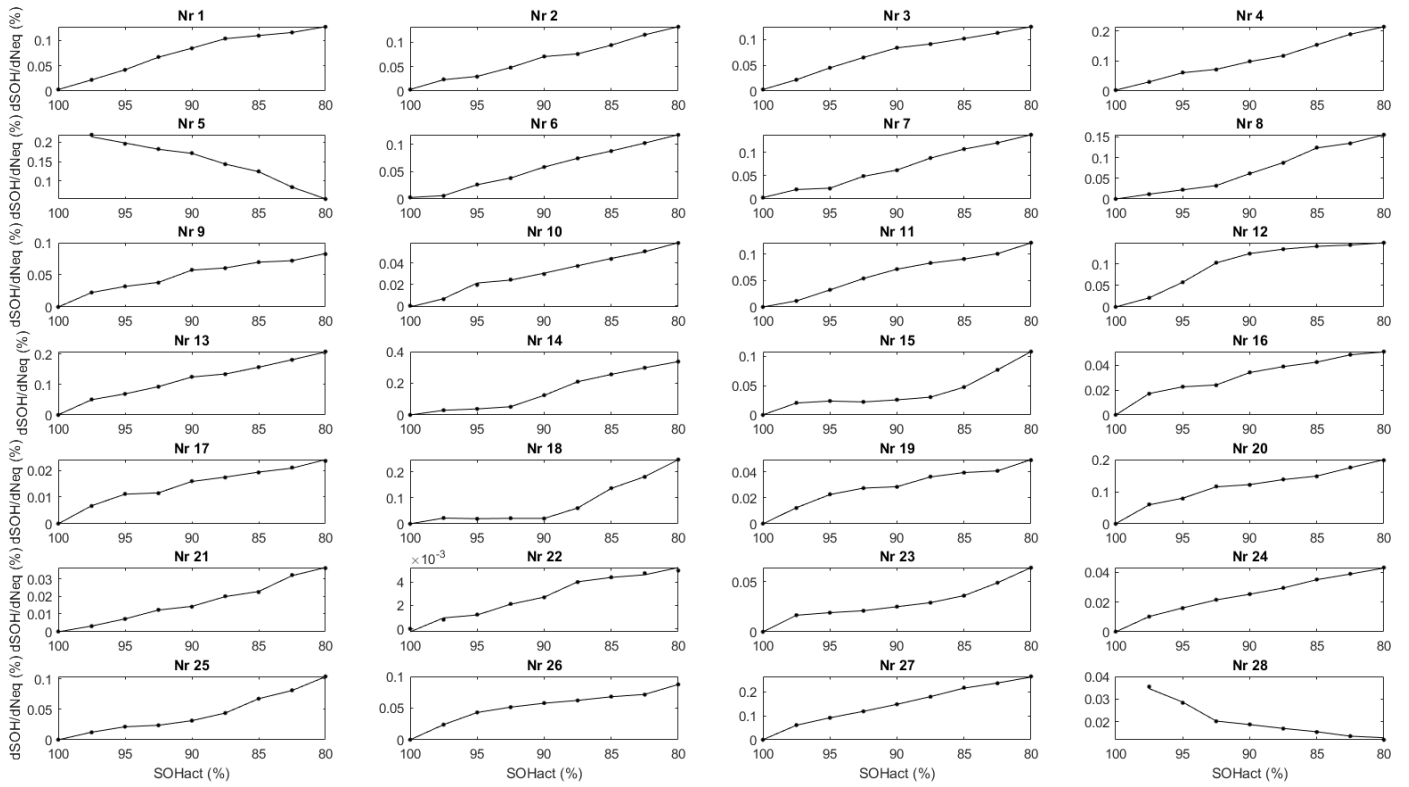
- [63] X. Li *et al.*, “A physics-based fractional order model and state of energy estimation for lithium ion batteries. Part II: Parameter identification and state of energy estimation for LiFePO₄ battery,” *J. Power Sources*, vol. 367, pp. 202–213, 2017.

Załącznik 1. Wartości dobranych parametrów pracy cyklicznej.

Wariant	Temperatura otoczenia (°C)	Prąd rozładowania (A)	Głębokość rozładowania (%)	Średni prąd ładowania (A)	Dotychczasowy stan zużycia (%)
1	10	2,6	73	2,4	
2	10	2,6	50	2,4	
3	10	2,6	27	1,8	
4	10	2,6	100	2,3	
5	10	7,8	100	2,6	
6	10	5,2	60	1,8	
7	10	2,6	67	1,7	
8	15	2,6	100	2,0	
9	15	5,2	100	2,3	
10	15	7,8	100	2,8	
11	15	5,2	50	2,2	
12	15	2,6	50	2,1	
13	15	5,2	100	1,8	
14	25	10,4	100	2,0	
15	25	7,8	100	2,8	
16	25	5,2	100	2,7	
17	25	2,6	100	2,0	
18	25	7,8	100	1,8	
19	25	5,2	100	2,0	
20	25	2,6	100	3,1	
21	25	5,2	50	2,2	
22	25	5,2	16	2,4	
23	40	7,8	100	2,8	
24	40	5,2	100	2,7	
25	40	2,6	100	2,4	
26	40	2,6	100	3,5	
27	25	2,6	100	3,3	
28	40	3,9	100	2,6	

Dla wszystkich ogniw *SOH* zawierał się w przedziale 100-80

Załącznik 2. Weryfikacja modelu – porównanie odpowiedzi modelu z wartościami eksperymentalnymi dla danych uczących.



Załącznik 3. Wartości parametrów pracy cyklicznej oraz wyniki wstępnych obliczeń.

ID ogniwa	T_c (C)	I_d (A)	I_{ch_avg} (A)	DoD (%)	FEC_{tot} (-)	RUE_c w <i>BoL</i> (-)	RUE_c w <i>EoL</i> (-)	ΔRUE_c (%)	E_{th_tot} (Wh)
H5	18,9	2,6	2,08	100	83	0,872	0,687	18,5	2302
A31	29	7,8	2,62	100	184	0,827	0,418	40,9	3451
D11	17,8	2,6	2,47	50	183	0,545	0,545	0	3435
B37	20,9	2,6	2,35	100	72	0,872	0,709	16,3	1516
A30	17,8	2,6	2,4	73	149	0,776	0,663	11,3	2753
H2	16,6	2,6	1,8	27	275	0,304	0,304	0	5029
A36	25,1	5,2	2,09	50	426	0,536	0,536	0	8002
D14	23,9	2,6	2,15	100	130	0,88	0,74	14	2517
B40	30,3	5,2	2,2	100	1054	0,875	0,55	32,5	19804
A35	32,5	7,8	2,52	100	664	0,865	0,33	53,5	12449
A20	25,7	5,2	1,81	100	209	0,942	0,704	23,8	3933
C33	32,7	2,6	3,04	74	306	0,789	0,749	4	5765
H10	33	2,6	2,78	74	344	0,795	0,759	3,6	6478
H9	35,3	2,6	2,85	100	226	0,945	0,752	19,3	4254
D16	43,2	7,8	2,64	100	905	0,911	0,294	61,7	16978
B32	39,7	5,2	2,66	100	676	0,922	0,672	25	13573
D1	33,2	5,2	2,38	16	3984	0,165	0,165	0	74901
A24	36,6	5,2	2,18	50	1721	0,546	0,546	0	32340
D4	29,2	2,6	1,2	100	1908	0,982	0,786	19,6	36109
C26	36,4	5,2	1,9	100	909	0,97	0,689	28,1	17083
A23	36,6	7,8	1,74	100	557	0,939	0,221	71,8	10458
H12	58,6	7,8	2,68	100	587	0,931	0,533	39,8	10993
H1	53,8	7,8	1,88	100	563	1,005	0,504	50,1	10555
D6	50,1	2,6	3,46	100	375	1,046	0,813	23,3	7048
B35	47,5	2,6	2,37	100	702	1,057	0,848	20,9	13206
A38	52,5	5,2	2,54	100	960	1,002	0,717	28,5	18034
H13	62,1	7,8	3,11	75	716	0,744	0,564	18	13409
C10	32,6	2,6	2,61	100	1460	0,995	0,798	19,7	27446
D2	33,7	2,6	3,2	100	160	0,934	0,742	19,2	3028

Załącznik 4. Dane dotyczące cytawalności poszczególnych artykułów naukowych w wybranych bazach naukowych.











Baza Web of Science Core Collection


10 Publications		Sort by: Citations: highest first		< 1 of 1 >		Citations						
						Previous year			Next year		Average per year	Total
						2018	2019	2020	2021	2022		
Total		9	8	6	9	6	7.17	43				
1	<p>Modelling and simulation of lead-acid battery pack powering electric vehicle</p> <p>Burzynski, D and Kasprzyk, L Energy and Fuels Conference 2017 ENERGY AND FUELS 2016 14</p>	8	3	2	1	0	3.17	19				
2	<p>Analysis and Modeling of the Wear-Out Process of a Lithium-Nickel-Manganese-Cobalt Cell during Cycling Operation under Constant Load Conditions</p> <p>Burzynski, D; Pietracho, B; (...); Tomczewski, A Oct 2019 ENERGIES 12 (20)</p>	0	0	2	4	1	1.75	7				
3	<p>A novel method for the modeling of the state of health of lithium-ion cells using machine learning for practical applications</p> <p>Burzynski, D and Kasprzyk, L May 11 2021 Mar 2021 (Early Access) KNOWLEDGE-BASED SYSTEMS 219</p> <p>Enriched Cited References</p>	0	0	0	1	3	2	4				
4	<p>Analysis of the impact of quick charge technology on the charging process parameters of the lithium-ion storage at various temperatures</p> <p>Burzynski, D; Gluchy, D and Godek, M Conference on Computer Applications in Electrical Engineering (ZKWE) 2018 COMPUTER APPLICATIONS IN ELECTRICAL ENGINEERING (ZKWE'2018) 19</p>	1	3	0	0	0	0.8	4				
5	<p>Modelling of lithium-ion batteries operation and life in electric vehicles</p> <p>Kasprzyk, L; Domeracka, A and Burzynski, D 2018 PRZEGLAD ELEKTROTECHNICZNY 94 (12) , pp.158-161</p>	0	1	1	1	1	0.8	4				
6	<p>Potential of Using Medium Electric Vehicle Fleet in a Commercial Enterprise Transport in Germany on the Basis of Real-World GPS Data</p> <p>Pietracho, B; Wenge, C; (...); Burzynski, D Sep 2021 ENERGIES 14 (17)</p> <p>Enriched Cited References</p>	0	0	0	1	1	1	2				
7	<p>The operation and capacity fade modelling of the lithium-ion cell for electric vehicles</p> <p>Burzynski, D and Kasprzyk, L Energy and Fuels Conference 2019 ENERGY AND FUELS 2018 108</p>	0	1	0	1	0	0.5	2				
8	<p>Electrical propulsion systems in vehicles - an overview of solutions</p> <p>Pietracho, B; Kasprzyk, L and Burzynski, D Conference on Applications of Electromagnetics in Modern Engineering and Medicine (PTZE) 2019 2019 APPLICATIONS OF ELECTROMAGNETICS IN MODERN ENGINEERING AND MEDICINE (PTZE) , pp.130-133</p>	0	0	1	0	0	0.25	1				
9	<p>Useful energy prediction model of a Lithium-ion cell operating on various duty cycles</p> <p>Burzynski, D 2022 EKSPLOATACJA I NIEZAWODNOSC-MAINTENANCE AND RELIABILITY 24 (2) , pp.317-329</p> <p>Enriched Cited References</p>	0	0	0	0	0	0	0				
10	<p>Modelling the operation of fuel cells in hydrogen vehicles</p> <p>Kasprzyk, L; Burzynski, D; (...); Wenge, C 2021 PRZEGLAD ELEKTROTECHNICZNY 97 (12) , pp.117-120</p>	0	0	0	0	0	0	0				

Citation Report Publications Table


Export all Add all to list

Sort by Cited by (highest) ▾

- Conference Paper • Open access
Modelling and simulation of lead-acid battery pack powering electric vehicle 22 Citations
 Burzyński, D., Kasprzyk, L.
E3S Web of Conferences, 2017, 14, 01041
Show abstract ▾  View at Publisher ↗ Related documents
- Article • Open access
Analysis and modeling of the wear-out process of a lithium-nickel-manganese-cobalt cell during cycling operation under constant load conditions 8 Citations
 Burzyński, D., Pietracho, R., Kasprzyk, L., Tomczewski, A.
Energies, 2019, 12(20), 3899
Show abstract ▾  View at Publisher ↗ Related documents
- Article
A novel method for the modeling of the state of health of lithium-ion cells using machine learning for practical applications 6 Citations
 Burzyński, D., Kasprzyk, L.
Knowledge-Based Systems, 2021, 219, 106900
Show abstract ▾  View at Publisher ↗ Related documents
- Article
Selected methods of modelling of the electrochemical cells operation | Wybrane metody modelowania pracy ogniw elektrochemicznych 6 Citations
 Burzyński, D., Kasprzyk, L.
Przegląd Elektrotechniczny, 2017, 93(12), pp. 75–78
Show abstract ▾  View at Publisher ↗ Related documents
- Article
Work simulation of lead-acid batteries | Symulacja pracy akumulatorów kwasowo-ołowiowych 5 Citations
 Kasprzyk, L., Bednarek, K., Burzyński, D.
Przegląd Elektrotechniczny, 2016, 92(12), pp. 61–64
Show abstract ▾  View at Publisher ↗ Related documents
- Article
Modelling of lithium-ion batteries operation and life in electric vehicles | Modelowanie pracy i trwałości akumulatorów litowo-jonowych w pojazdach elektrycznych 3 Citations
 Kasprzyk, L., Domeracka, A., Burzyński, D.
Przegląd Elektrotechniczny, 2018, 94(12), pp. 158–161
Show abstract ▾  View at Publisher ↗ Related documents
- Article • Open access
Potential of using medium electric vehicle fleet in a commercial enterprise transport in Germany on the basis of real-world GPS data 2 Citations
 Pietracho, R., Wenge, C., Balischewski, S., ...Kasprzyk, L., Burzyński, D.
Energies, 2021, 14(17), 5327
Show abstract ▾  View at Publisher ↗ Related documents
- Conference Paper • Open access
The operation and capacity fade modelling of the lithium-ion cell for electric vehicles 2 Citations
 Burzyński, D., Kasprzyk, L.
E3S Web of Conferences, 2019, 108, 01017
Show abstract ▾  View at Publisher ↗ Related documents
- Conference Paper • Open access
Analysis of the potential use of lithium-ion energy storage in the home charging station for electric cars 2 Citations
 Burzyński, D., Kasprzyk, L.
IOP Conference Series: Earth and Environmental Science, 2019, 214(1), 012077
Show abstract ▾  View at Publisher ↗ Related documents
- Conference Paper
Electrical propulsion systems in vehicles - An overview of solutions 1 Citations
 Pietracho, R., Kasprzyk, L., Burzyński, D.
2019 Applications of Electromagnetics in Modern Engineering and Medicine, PTZE 2019, 2019, pp. 130–133, 8781696
Show abstract ▾  View at Publisher ↗ Related documents

Article • Open access
 Useful energy prediction model of a Lithium-ion cell operating on various duty cycles
 Burzyński, D.
Eksploatacja i Niezawodność, 2022, 24(2), pp. 317–329
[Show abstract](#)  [View at Publisher](#) [Related documents](#)

0
 Citations

Article
 Modelling the operation of fuel cells in hydrogen vehicles |
 Modelowanie pracy ogniw paliwowych w pojazdach wodorowych
 Kasprzyk, L., Burzyński, D., Lewandowska, A., ...Wenge, C.W.H., Szymenderski, J.
Przegląd Elektrotechniczny, 2021, 97(12), pp. 117–120
[Show abstract](#)  [View at Publisher](#) [Related documents](#)

0
 Citations

Baza Google Scholar

TYTUŁ	CYTOWANE PRZEZ	ROK
Modelling and simulation of lead-acid battery pack powering electric vehicle D Burzyński, L Kasprzyk E3S Web of Conferences 14, 01041	28	2017
Analysis and modeling of the wear-out process of a lithium-nickel-manganese-cobalt cell during cycling operation under constant load conditions D Burzyński, R Pietracho, L Kasprzyk, A Tomczewski Energies 12 (20), 3899	10	2019
Symulacja pracy akumulatorów kwasowo-ołowiowych L KASPRZYK, K BEDNAREK, D BURZYŃSKI TIC 1 (1), 0	8	2016
A novel method for the modeling of the state of health of lithium-ion cells using machine learning for practical applications D Burzyński, L Kasprzyk Knowledge-Based Systems 219, 106900	7	2021
Wybrane metody modelowania pracy ogniw elektrochemicznych D Burzyński, L Kasprzyk Przegląd Elektrotechniczny 93, 75-78	6	2017
Analysis of the potential use of lithium-ion energy storage in the home charging station for electric cars D Burzyński, L Kasprzyk IOP Conference Series: Earth and Environmental Science 214 (1), 012077	3	2019
Modelling of lithium-ion batteries operation and life in electric vehicles L Kasprzyk, A Domeracka, D Burzynski Prz. Elektrotechniczny 1, 160-163	3	2018
Analysis of the impact of quick charge technology on the charging process parameters of the lithium-ion storage at various temperatures D Burzyński, D Głuchy, M Godek ITM Web of Conferences 19, 01035	3	2018
The operation and capacity fade modelling of the lithium-ion cell for electric vehicles D Burzyński, L Kasprzyk E3S Web of Conferences 108, 01017	2	2019
Potential of Using Medium Electric Vehicle Fleet in a Commercial Enterprise Transport in Germany on the Basis of Real-World GPS Data R Pietracho, C Wenge, S Balischewski, P Lombardi, P Komarnicki, ... Energies 14 (17), 5327	1	2021
Electrical propulsion systems in vehicles—an overview of solutions R Pietracho, L Kasprzyk, D Burzyński 2019 Applications of Electromagnetics in Modern Engineering and Medicine ...	1	2019

<p>Modelowanie pracy i trwałości akumulatorów litowo-jonowych w pojazdach elektrycznych L Kasprzyk, A Domeracka, D Burzyński Przeгляд Elektrotechniczny 94</p>	<p>1 2018</p>
<p>Useful Energy Prediction Model of a Lithium-ion Cell Operating on Various Duty Cycles D Burzyński TechRxiv</p>	<p>2021</p>
<p>Wpływ temperatury na parametry procesu ładowania z wykorzystaniem technologii Quick Charge oraz trwałość ogniw litowo-jonowych D Burzyński, D Głuchy, M Godek Poznan University of Technology Academic Journals. Electrical Engineering</p>	<p>2018</p>
<p>Modelowanie pracy akumulatorów kwasowo-ołowiowych w stanach dynamicznych D Burzyński, L Kasprzyk Poznan University of Technology Academic Journals. Electrical Engineering</p>	<p>2017</p>
<p>Modelowanie zachowania się akumulatora kwasowo-ołowiowego podczas jazdy samochodu elektrycznego z wykorzystaniem środowiska MATLAB L Kasprzyk, D Burzyński Poznan University of Technology Academic Journals. Electrical Engineering</p>	<p>2016</p>
<p>Use of LabVIEW software for electromagnetic calculation of induction motors D Burzyński, L Kasprzyk Computer Applications in Electrical Engineering 13, 364–375</p>	<p>2015</p>
<p>Aplikacja napisana w środowisku LabVIEW służąca do wyznaczania współczynnika uzwojenia maszyny indukcyjnej D Burzyński, L Kasprzyk Poznan University of Technology Academic Journals. Electrical Engineering</p>	<p>2015</p>

Useful energy prediction model of a Lithium-ion cell operating on various duty cycles

Damian Burzyński^a

^aPoznan University of Technology, Faculty of Control, Robotics and Electrical Engineering, ul. Piotrowo 3a, 60-965 Poznan, Poland

Indexed by:




Highlights

- A new non-parametric useful energy model for long-term prediction was developed.
- Developed model takes into account the lifetime degradation of the cell.
- Identification of three types of RUE_c evolution over exploitation period of the cells.
- XAI techniques were used to quantify effect of model parameters on RUE_c .
- The proposed methodology can be applied to electrochemical cells of other types.

Abstract

The paper deals with the subject of the prediction of useful energy during the cycling of a lithium-ion cell (LIC), using machine learning-based techniques. It was demonstrated that depending on the combination of cycling parameters, the useful energy (RUE_c) that can be transferred during a full cycle is variable, and also three different types of evolution of changes in RUE_c were identified. The paper presents a new non-parametric RUE_c prediction model based on Gaussian process regression. It was proven that the proposed methodology enables the RUE_c prediction for LICs discharged, above the depth of discharge, at a level of 70% with an acceptable error, which is confirmed for new load profiles. Furthermore, techniques associated with explainable artificial intelligence were applied to determine the significance of model input parameters – the variable importance method – and to determine the quantitative effect of individual model parameters (their reciprocal interaction) on RUE_c – the accumulated local effects model of the first and second order.

Keywords

This is an open access article under the CC BY license (<https://creativecommons.org/licenses/by/4.0/>) 

cycle life modelling, lithium-ion battery, machine learning, predictive models, useful energy prediction.

1. Introduction

In recent years, it is possible to observe a rapid increase in the demand for equipment designed for electric energy storage. At present, it is estimated that the highest increase refers to the industry branch related to electromobility, where solutions based on lithium-ion batteries are currently dominant [40]. It is predicted that by the end of 2030, the demand for batteries will increase ten times in this sector alone [13, 41].

The prevailing share of lithium-ion batteries on the market follows primarily from their ability to transfer energy quickly and effectively, whereby this ability is successively increased owing to the dynamic development of electrochemical battery technology [7].

The key issue related to the operation of these storages is their life. Degradation of lithium-ion cells (LICs) is a consequence of aging processes which take place during cycling, and also during the storage period [4, 54]. Out of more than a dozen identified aging phenomena, lithium plating, formation, evolution and dissolution of the solid electrolyte interface, as well as electrolyte decomposition, particle gassing and corrosion of the current collectors are the pre-dominant contributors to the degradation process [56]. Without interference in the LIC structure, the effects of the aging processes may be determined through the loss in charge throughput and the increase in internal resistance (or impedance).

1.1. Related papers

Based on the current state of knowledge, it can be concluded that in the case of LICs, usually separate degradation models are developed for cycling (cycle life) and storage period (calendar aging). The calendar aging models usually include two parameters: the ambient temperature (T_a) at which a cell is stored and the state of charge (SoC) [2, 3, 23, 64]. On the other hand, degradation models during cycling are multi-parameter models – their parameters include: values of discharge/charge current (I_d/I_{ch}), depth of discharge (DoD), cell temperature (T_c) or ambient temperature, as well as the charge or energy throughput (expressed most frequently as the number of full equivalent cycles – FECs). At this point, it must be emphasised that some of these parameters are correlated with each other and their effect on the amount of energy throughput of LICs is non-linear [38]. The above-mentioned facts make analysing and predicting the LICs' ability to transfer energy over the period of their lifetime highly complicated and require advanced methods [21]. In addition to this, testing electrochemical cells is very time-consuming due to their life. The testing of a single variant may last even a few years. For this reason, a more and more frequent practice is to conduct the testing under conditions which result in their accelerated degradation (e.g. under an increased load or at extreme temperatures), and then to predict their operational parameters under the assumed operating conditions [8, 12].

E-mail addresses: D. Burzyński (ORCID: 0000-0001-7874-1376): damian.burzynski@put.poznan.pl

It is possible to distinguish two main approaches in the modelling of LICs' degradation: physico-chemical models and empirical models. The physico-chemical models usually consist of several partial differential equations, by means of which, the effect of the respective aging processes on the capacity fade of LICs is modelled. Examples of such models, for the Li_xCoO_2 cell can be found in papers [37, 45, 50]. The advantage of physico-chemical models is the possibility of mapping changes taking place in each part of a LIC as a consequence of cycling, however, the identification of their parameters and implementation are highly complicated. A frequent approach among researchers is the use of methods based on regression [16, 36, 48, 53, 58]. In such models, in the majority of cases, the effect of selected cycling parameters on LIC degradation is analysed. A paper by [15] studied the effect of certain parameters of the charging half-cycle, the charge currents (I_{ch}) and final charge voltages (U_{ch}), on the process of the actual capacity fade of a LiCoO_2 cell. The testing was conducted at one charge current level (1C) and at a temperature of 25°C. Xiong *et al.* [67] developed a model which enables prediction of the remaining useful life of a battery (RUL) for a LiNiCoAlO_2 cell. The tests were conducted under conditions of accelerated aging – at discharge currents $I_d = 1\text{C}$ and $I_d = 2\text{C}$ and at temperatures $T_a = 25^\circ\text{C}$ and $T_a = 40^\circ\text{C}$. Effect of fluctuating ambient temperature on the capacity loss process of LiFePO_4 cell was investigated and modeled in the paper [33]. In paper [35] Dessaint *et al.* implemented two multi-parametric models which allow for the determination of the maximum number of cycles which may be carried out by LiNiMnCoO_2 and LiFePO_4 cells, depending on the actual cycling parameters (I_d, I_{ch}, DoD, T_a). On the other hand, in paper [57] Wang *et al.* took into account the charge throughput in addition to typical cycling parameters (I_d, I_{ch}, DoD, T_c) to determine the capacity fade of a LiFePO_4 cell.

Among other approaches related to the modelling of degradation during LIC cycling, it is necessary to mention the destructive method based on the Palmgren-Miner damage accumulation theory [11,46] and the non-destructive method based on electrochemical impedance spectroscopy (EIS). Zhang *et al.* [69] proposed a forecasting methodology for the RUL of lithium-ion batteries using EIS and Gaussian process regression (GPR). In turn, Saha *et al.* in [47] used EIS and the Bayesian statistical approach to develop a new RUL method.

Moreover, as methods based on machine intelligence are being developed, it is possible to observe their more and more frequent use in problems related to the prediction of operational parameters of LICs such as, e.g. remaining useful life (RUL) [17, 32, 51] or capacity [43, 49]. These methods are strictly based on data which are usually acquired from many-months of experimental procedures [5, 10, 22, 28, 55]. In [19], Hannan *et al.* proposed the use of a deep neural network to determine the *SoC* for LiNiMnCoO_2 cells. Li *et al.* [29] developed a method for estimating the capacity of LiFePO_4 cells, based on a convolutional neural network. Moreover, the use of support vector machines was proposed in papers by [26, 63] to predict the state of health (*SoH*) of batteries. In [24], Li *et al.* proved that the *SoC* of a battery may be predicted with high accuracy by a structure which is a merger of the neural network and fuzzy logic. In the past, approaches based on sample entropy [20], fuzzy logic [6] and Rao-Blackwellization particle filter [14] have also been used to determine the RUL.

The GPR technique used in that paper had previously been used to predict the capacity fade or RUL. In [44], Howey *et al.* developed a model to predict the capacity fade of a LiCoO_2 cell under variable load and temperature conditions. On the other hand in [52] Hariharan *et al.* used the deep GPR to estimate the end of life (*EoL*) – the chemical composition of the cell was not specified. GPR was also used to predict battery degradation during calendar aging, and this issue was touched upon in paper by [31].

Because of the fact that, for some designers of systems powered from cells, *SoH* is not always a sufficient assessment indicator, other methods which enable the determination and prediction of the avail-

able power and energy in LICs have been developed recently [39, 65]. In [66], an attempt was made to predict the energy available in the battery for two cells - LiNiMnCoO_2 and LiFePO_4 , using particle filtering. In a paper by [25], the state of the available energy at different I_d and at different T_a , taking into account degradation, was determined for a $\text{Li}_4\text{Ti}_5\text{O}_{12}$ cell using a circuit model. Dong *et al.* [9] developed a state of energy estimation method for LiFePO_4 cells using neural network achieving an error of less than 4%. The analyses were conducted at different ambient temperatures and discharge currents. In the papers [30,68] methods based on predictive control theory were implemented to predict the energy of an LiNiMnCoO_2 cell and a package of LiNiMnCoO_2 cells. Another approach using an adaptive method based on an extended Kalman filter to estimate the remaining energy of LiFePO_4 and LiNiMnCoO_2 cells are presented in [60, 61]. Wang *et al.* [59] proposed a joint estimator based on particle filter to determine both the state of energy and *SoC* of the LiFePO_4 cell. It should be noted here that the cell parameters studies were conducted with variation in discharge currents and at four ambient temperature levels. Fractional-order physics models can be also used to determine the state of energy with less than 5% error, as demonstrated in the paper [27].

1.2. Key contributions

Although many different approaches have been developed to date in the aspect of modelling the effects of aging phenomena occurring in LICs, in particular the prediction of available energy and power, this issue has not yet been sufficiently explored. In many applications, not only is knowledge of the predicted useful energy of the LIC over its lifetime required, but also of the predicted changes in degradation trends. In many research centres around the world, complex models are currently being developed that take into account many parameters of cyclic operation, such as ambient temperature, discharge current and, increasingly *SoH*. For this reason, the following contributions have been made in this paper:

- 1) A major contribution is the development of a machine learning based model that allows long-term prediction of the useful energy that the LIC is able to transfer during a single duty cycle taking into account its lifetime degradation which is a significant improvement of currently existing methods. The proposed model has a new structure of input parameters – given the negative effect of higher currents during charging proven in the literature [15], the model separately considers the effect of discharging and charging current.
- 2) The result of this research is a new dataset that can be used to test current methods and develop new predictive methods for the useful energy or *SoH* of LICs.
- 3) A demonstration of the variability of RUE_c depending on the combination of cycling parameters, and also identification of three types of evolution of changes in RUE_c in the period of operation of the LIC under consideration.
- 4) For the first time, the following techniques have been used: explainable artificial intelligence (XAI) – variable importance (VI) – to determine the significance of parameters of the GPR model, and accumulated local effects (ALE) – to determine their quantitative effect on RUE_c .

1.3. Structure of the paper

The remaining part of the paper is organised as follows. Chapter II outlines the procedure for obtaining experimental data and determining the useful energy RUE_c and also describes the results of preliminary analyses and calculations. Chapter III presents the applied methodology, GPR and XAI techniques. The results obtained and the discussion of the verification procedure are included in chapter IV. The final remarks and the conclusion are presented in chapter V.




Fig. 1. Block diagram of the experimental procedure

Algorithm 1: Q_{ref} determination

1. Interruption of the currently running aging variant after completion of the charge half-cycle (not applicable to BoL)
2. Set the temperature of the cell to 25°C
3. Charging of the cell to 4.2 V with 1.3 A current in accordance with procedure CC-CV until the current in the CV phase drops to 0.065 A
4. 15-second break
5. Discharge of the cell to 2.75 V with the -2.6 A current (CC method)
6. Calculation of the cell capacity using the Coulomb counting method – equation (2)

2. Data preparation

In order to obtain data related to the ability of LICs to transfer energy during cycling, they were subjected to aging tests under various load and temperature conditions. Commercial Samsung 18650 LICs (cylindrical), with a nominal capacity of 2600 mAh (C_{nom}) and nominal voltage of 3.63 V (U_{nom}) were selected for the tests. The cathode material of the tested cells was composed of $\text{LiNi}_{0.33}\text{Mn}_{0.33}\text{Co}_{0.33}\text{O}_2$ compound, while the anode was made of graphite.

2.1. Experimental procedure

The procedure presented in Fig. 1 was adopted for the purpose of performing aging tests. Before starting the aging procedure of each cell, their reference tests charge (Q_{ref}) was determined in accordance with algorithm 1.

Then, each of the cells was subjected to cycling under unique temperature and load conditions. During the tests, a Panasonic MIR-254 temperature chamber was used to maintain a constant ambient temperature. The T_a range in which the cells were cycled was between 10°C and 40°C. Momentary temperatures of cells were recorded by means of probes located in central points of the cells. The discharge half-cycles were completed using the constant-current (CC) method, while charge half-cycles were completed using the constant-current constant-voltage (CC-CV) method. Val-

ues I_d and I_{ch} were selected from the range between -2.6 A and -7.8 A (for discharge) and between 1.3 A and 7.8 A (during the CC charge phase). The average charge current from all half-cycles completed from BoL ($SoH = 100\%$) to EoL ($SoH = 80\%$) was adopted as the value of charge current during analyses. During the experimental procedures, LICs were kept in the voltage operating window specified by the manufacturer, i.e. from 2.75 V (U_{dsch}) to 4.2 V (U_{ch}). Several DoD levels were selected ranging between 16% and 100%, with an assumption that DoD is the charge which can be obtained in the given combination of cycling parameters. For example $DoD = 100\%$ corresponds to a discharge in the full voltage operating window. The interval between charge and discharge half-cycles was constant and was equal to 15 s. The cell cycling process was controlled by a Cadex C8000 tester dedicated to electrochemical cells (values of momentary currents, voltages and temperatures of LICs were measured using separate wires). The current/voltage measurement accuracy amounted to ± 0.001 A/V while the temperature measurement accuracy was $\pm 0.1^\circ\text{C}$. To sum up, 29 cells in total were tested at four different T_a (10°C, 15°C, 25°C and 40°C), at 3 different values of I_d (-2.6 A, -5.2 A and -7.8 A) and at 5 different DoD levels (16%, 27%, 50%, 75% and 100%). The average value of charge current ($I_{ch, avg}$) ranged between 1.2 A and 3.46 A. Table I contains detailed values of the cycling parameters adopted during the aging tests.

The condition for completion of each aging procedure was the degradation of the cell to $SoH = 80\%$. The actual SoH of the cells was checked every 48 hours under reference conditions (described in algorithm 1) using the following relationship (1):

$$SoH = \frac{Q_{ref}}{Q_{BoL}} \cdot 100\% \quad (1)$$

TABLE I
VALUES OF CYCLING PARAMETERS SELECTED FOR AGING PROCEDURES AND RESULTS OBTAINED FROM INITIAL CALCULATIONS

Cell ID	T_c (°C)	I_d (A)	$I_{s, avg}$ (A)	DoD (%)	FEC _{int} (-)	RUE _{at BoL} (-)	RUE _{at EoL} (-)	ΔRUE_c (%)	$E_{in, int}$ (Wh)
H5	18.9	-2.6	2.08	100	83	0.872	0.687	18.5	2302
A31	29	-7.8	2.62	100	184	0.827	0.418	40.9	3451
D11	17.8	-2.6	2.47	50	183	0.545	0.545	0	3435
B37	20.9	-2.6	2.35	100	72	0.872	0.709	16.3	1516
A30	17.8	-2.6	2.4	73	149	0.776	0.663	11.3	2753
H2	16.6	-2.6	1.8	27	275	0.304	0.304	0	5029
A36	25.1	-5.2	2.09	50	426	0.536	0.536	0	8002
D14	23.9	-2.6	2.15	100	130	0.88	0.74	14	2517
B40	30.3	-5.2	2.2	100	1054	0.875	0.55	32.5	19804
A35	32.5	-7.8	2.52	100	664	0.865	0.33	53.5	12449
A20	25.7	-5.2	1.81	100	209	0.942	0.704	23.8	3933
C33	32.7	-2.6	3.04	74	306	0.789	0.749	4	5765
H10	33	-2.6	2.78	74	344	0.795	0.759	3.6	6478
H9	35.3	-2.6	2.85	100	226	0.945	0.752	19.3	4254
D16	43.2	-7.8	2.64	100	905	0.911	0.294	61.7	16978
B32	39.7	-5.2	2.66	100	676	0.922	0.672	25	13573
D1	33.2	-5.2	2.38	16	3984	0.165	0.165	0	74901
A24	36.6	-5.2	2.18	50	1721	0.546	0.546	0	32340
D4	29.2	-2.6	1.2	100	1908	0.982	0.786	19.6	36109
C26	36.4	-5.2	1.9	100	909	0.97	0.689	28.1	17083
A23	36.6	-7.8	1.74	100	557	0.939	0.221	71.8	10458
H12	58.6	-7.8	2.68	100	587	0.931	0.533	39.8	10993
H1	53.8	-7.8	1.88	100	563	1.005	0.504	50.1	10555
D6	50.1	-2.6	3.46	100	375	1.046	0.813	23.3	7048
B35	47.5	-2.6	2.37	100	702	1.057	0.848	20.9	13206
A38	52.5	-5.2	2.54	100	960	1.002	0.717	28.5	18034
H13	62.1	-7.8	3.11	75	716	0.744	0.564	18	13409
C10	32.6	-2.6	2.61	100	1460	0.995	0.798	19.7	27446
D2	33.7	-2.6	3.2	100	160	0.934	0.742	19.2	3028

where Q_{ref} is the collected charge, Q_{BoL} is the charge collected before the start of the LIC cycling.

2.2. Useful energy determination

In order to determine the useful energy throughput of a LIC during a single duty cycle over its entire life, the following methodology was adopted:

- 1) The assumption that one complete duty cycle consists of a discharge half-cycle and the immediately following charge half-cycle.
- 2) Calculation of the charge throughput during a single duty cycle (collected during discharge Q_{dsch} and charge Q_{ch}) using the Coulomb Counting method, on the basis of equation (2).

- 3) Determination of the relative useful energy RUE_c throughput during the duty cycle in accordance with relationship (3). $RUE_c=1$ means that a cell transferred nominal energy (18.876 Wh) during a full duty cycle (a discharge followed by a charge).
- 4) After each control procedure, determination of the number of completed full equivalent duty cycles (FECs) for the needs of the prediction model.
- 5) Determination of FEC_{tot} as the sum of RUE_c from all completed LIC duty cycles from BoL to EoL . An assumption was made that the transfer of nominal energy (18.876 Wh) during two consecutive charge and discharge half-cycles constitutes a full equivalent cycle (FEC).
- 6) Determination of the total energy throughput $E_{th,tot}$ as a product of total charge throughput of LIC, multiplied by its voltage on terminals:

$$Q_{ch/dsch} = Q_0 + \int_0^t I_{ch/dsch}(t) dt \quad (2)$$

$$RUE_c = \frac{Q_{dsch} \cdot U_{ave_dsch} + Q_{ch} \cdot U_{ave_ch}}{2 \cdot C_{nom} \cdot U_{nom}} \quad (3)$$

where Q_0 is the initial charge accumulated in a LIC, U_{ave_dsch} is an average voltage during a discharge half-cycle, U_{ave_ch} is an average voltage during a charge half-cycle, C_{nom} is the nominal capacity and U_{nom} is the nominal voltage.

2.3. Initial analysis and calculations

The tests carried out showed that for the LICs discharged to $DoD > 70\%$ the value of the transferred RUE_c is variable during their considered life. In the case of variants with $DoD < 70\%$, LICs transferred the fixed energy throughout their life ($RUE_c = const$). Depending on the combination of the values of the cycling parameters, three types of evolution of RUE_c changes were observed during the analysed period of operation: a) approximately linear, b) a slow decrease in the first phase of life followed by a phase of accelerated loss of energy transfer, c) a characteristic inflection point occurred after the phase of releasing the assumed charge, followed by a phase of rapid loss of energy transfer. The phenomena described in points b) and c) were present in cells "A23", "D14", "D16", "A30", "H10", "A20", "B37", "H5" and "C33". Moreover, it was observed that the lower the average temperature during full duty cycle (T_c), the more rapidly the process of RUE_c loss proceeded. For LICs with $T_c > 30^\circ C$ in most cases (except "B35", "D16" and "A23") this phenomenon proceed approximately linearly. The selected characteristics of the RUE_c of cells, in which the effect described above occurred, are presented in Fig. 2.

For each completed aging variant, it was checked how the ability of the cell to transfer RUE_c decreased. For this purpose, the ΔRUE_c difference (eq. 4) between RUE_c determined at BoL and EoL was calculated.

$$\Delta RUE_c = (RUE_{c_BoL} - RUE_{c_EoL}) \cdot 100\% \quad (4)$$

Depending on the cycling conditions ΔRUE_c reached values exceeding 50% (cells: "A35", "D16", "H1" and "H23") which means that in the period preceding EoL the cells were not capable of transferring even half of the initial RUE_c . A high value of ΔRUE_c was observed for cells discharged with a high current (-7.8 A) regardless of the temperature conditions (average cyclic temperature of the cell). The lowest values of ΔRUE_c occurred for cycled cells at incomplete DoD ("A30", "C33", "H10" and "H13").




Fig. 2. Three types of evolution of RUE_c trends observed for the tested LIC

Additionally, FEC_{tot} and $E_{th,tot}$ completed by each LIC were determined and listed for information purposes in Table I. The statistical values of measuring data and initial calculations are included in Table II. Raw results of experimental measurements and FEC calculations of all LICs are available online (raw data: <https://data.mendeley.com/datasets/fzp5wx28kw/1>).

TABLE II
STATISTICAL VALUES OF THE DATA OBTAINED FROM EXPERIMENTAL AND INITIAL CALCULATIONS

Parameter	T_c ($^\circ C$)	I_d (A)	$I_{ch,avg}$ (A)	DoD (%)	RUE_c (-)
Missing values	0	0	0	0	0
Minimum	17.7	-2.6	1.213	73	0.221
Maximum	58.6	-7.8	3.46	100	1.057
Median	33	-2.6	2.4	100	0.823
Mean	36.9	-4.67	2.23	96.7	0.811
Std. dev.	10.41	2.41	0.603	8.69	0.14
Variance	108.3	5.82	0.364	75.4	0.02
25 % percentile	29.2	-7.8	1.88	100	0.757
75 % percentile	45.5	-2.6	2.6	100	0.907
Number of different values	19	3	18	3	211

3. Proposed methodology

3.1. Data pre-processing

An inseparable part of prediction models based on machine learning is data pre-processing. The techniques used in data pre-processing enable assessment of the quality of the data and their usefulness, which translates directly into the ability of the created model to learn. Due to the numerical nature of the data used, it was not necessary to use methods related to the handling of categorical variables and null values. Before initiating the machine learning procedure, the data obtained from the experimental measurements were normalised. After the normalisation, the average value of each of the parameters of the learning dataset was equal to 0, and the standard deviation was equal to 1.

3.2. Proposed model

The amount of RUE_c which LICs are capable of transferring during a full duty cycle over their lifetime depends on the combination of values of cyclic operating parameters and the number of completed $FECs$. As the tests demonstrated, LICs may have a similar ability to transfer RUE_c even if they have completed a significantly different number of $FECs$. One additional issue is the fact that the cyclic operating parameters of a LIC are strongly correlated. For instance higher values of DoD , I_d and $I_{ch,avg}$ result in an increase in the average temperature of the LIC, which, in turn, determines the amount of RUE_c . Furthermore, the impossibility of separating the impact of the above-mentioned parameters during a duty cycle makes it highly difficult to determine the precise effect of individual parameters on the amount of RUE_c . In this paper, in order to develop a prediction model for the relative useful energy RUE_c the framework presented in Fig. 3 was adopted.

Taking the above-mentioned challenges into account, the author proposes the use of the non-parametric model, whose structure strictly matches the form of learning data. This model belongs to the group of machine learning models (with supervision); it is more frequently referred to as GPR and is a non-parametric regression technique based on Gauss processes. This approach has many advantages, the most important being the lack of requirements to know the distributions of the model parameters and the correlations between them, and also a high prediction accuracy even when using a small learning dataset. Additionally, it forces out the use of techniques which enable the interpretation of the manner in which the implemented non-parametric model operations. These techniques belong to the so called explainable artificial intelligence XAI. In this paper, the author have applied a method that makes it possible to determine the significance of explanatory variables in the model. For the purpose of quantitative determination of the effect which the respective model variables have on the predicted value (taking into account the correlation of other parameters), the concept of accumulated local effects (ALE) has been used.

3.3. Gaussian process regression

Gaussian process regression (GPR) belongs to the group of kernel-based non-parametric models [42]. In this model, the Gaussian probability distribution is defined for each finite set of input variables x_i :

$$f(x) \sim GP(\mu(x), cov(x, x')) \quad (5)$$

where $\mu(x)$ is mean function, and $cov(x, x')$ is the covariance function (kernel function).

The mean and covariance functions are expressed as:

$$\mu(x) = E(f(x)) \quad (6)$$

$$cov(x, x') = E((f(x) - \mu(x))(f(x') - \mu(x')))) = k(x, x') \quad (7)$$

where E is an expected value.

The mean function may be equal to zero and may be a constant or mean value of the learning dataset. On the other hand, the kernel function may have various specific forms ranging from the standard ones, such as constant, linear, radial, squared exponential or matern, as well as being a composite of multiple kernel functions. The kernel functions contain parameters related to the scaling of responses of model y and input vector x and are referred to as hyperparameters θ . For the majority of standard kernels, the hyperparameters include: standard deviation σ_f and characteristic length σ_l . For all the parameters of the input vector of the model, the characteristic length may be identical or different.




Fig. 4. Graphic representation of the GPR model

The matching of the structure of the model to the learning set takes place by defining, for each sample of the learning dataset x_i , a function $f(x_i)$ having the Gaussian distribution – hereafter called a hidden variable – and a set of basis functions $h(x)$, which transfer the input vector x_i from the original feature space R^d to the extended feature space R^p . The graphic representation of the GPR model is presented in Fig. 4. The known values (learning dataset) are marked in circles with continuous lines, while the hidden variables of the GPR model are mapped using rectangles. The hidden variables are connected by a thin horizontal line and, taking into account the marginalisation property of the model, each data sample (x_i, y_i) is independent of the others. Points (x^*, y^*) in circles with dashed lines mean new data points.

By using the kernel functions, it is possible to determine how model prediction y for vector x is dependent on the response in other points x' . It determines the similarity between the two points (x, x') in the scalar form $k(x, x')$. More details related to kernel functions can be found in [18].

For the needs of the RUE_c prediction, the following structure of the model has been adopted:

$$y(x) = h(x)^T w + f(x) + \varepsilon \quad (8)$$

where $h(x)$ is the set of basis functions, w is the vector of basis function coefficients, ε is noise with normal distribution.

Model prediction y takes place on the basis of input vector x' and the learning dataset:

$$P(y_i | f(x_i), x_i) \sim N(y_i | h(x_i)^T w + f(x_i), \sigma^2) \quad (9)$$

The above-mentioned model may be expressed in the form of a vector using the following relationship:

$$P(\mathbf{y} | \mathbf{f}, \mathbf{X}) \sim N(\mathbf{y} | \mathbf{H}\mathbf{w} + \mathbf{f}, \mathbf{I}\sigma^2) \quad (10)$$

where σ is the standard deviation, \mathbf{I}_n is the identity matrix and:

$$\mathbf{X} = (x_1^T \ x_2^T \ \dots \ x_n^T)^T \quad (11)$$

$$\mathbf{f} = (f(x_1) \ f(x_2) \ \dots \ f(x_n))^T \quad (12)$$

$$\mathbf{H} = (h(x_1^T) \ h(x_2^T) \ \dots \ h(x_n^T))^T \quad (13)$$

$$\mathbf{y} = (y_1 \ y_2 \ \dots \ y_n)^T \quad (14)$$

Joint probability distribution of latent variables \mathbf{f} with an assumption of a zero mean function $\mu(x)=0$ is expressed as follows:

$$P(\mathbf{f}|\mathbf{X}) \sim N(\mathbf{f}|0, \mathbf{K}(\mathbf{X}, \mathbf{X}')) \quad (15)$$

where:

$$\mathbf{K}(\mathbf{X}, \mathbf{X}') = \begin{pmatrix} k(x_1, x_1') & k(x_1, x_2') & \cdots & k(x_1, x_n') \\ k(x_2, x_1') & k(x_2, x_2') & \cdots & k(x_2, x_n') \\ \vdots & \vdots & \ddots & \vdots \\ k(x_n, x_1') & k(x_n, x_2') & \cdots & k(x_n, x_n') \end{pmatrix} \quad (16)$$

The values of the hyperparameters of the kernel function can be determined by maximisation of the logarithmic membership function $P(\mathbf{y}|\mathbf{X})$ with respect to parameters \mathbf{w}, θ and σ^2 using the following relationship:

$$\mathbf{w}, \theta, \sigma^2 = \arg \max_{\mathbf{w}, \theta, \sigma^2} \log P(\mathbf{y}|\mathbf{X}, \mathbf{w}, \theta, \sigma^2) \quad (17)$$

Taking into account that:

$$P(\mathbf{y}|\mathbf{X}, \mathbf{w}, \theta, \sigma^2) = N(\mathbf{y}|\mathbf{H}\mathbf{w}, \mathbf{K}(\mathbf{X}, \mathbf{X}') + \mathbf{I}\sigma^2) \quad (18)$$

the logarithmic membership function may be represented as:

$$\log P(\mathbf{y}|\mathbf{X}, \mathbf{w}, \theta, \sigma^2) = -\frac{1}{2}(\mathbf{y} - \mathbf{H}\mathbf{w})^T [\mathbf{K}(\mathbf{X}, \mathbf{X}') + \mathbf{I}\sigma^2]^{-1} (\mathbf{y} - \mathbf{H}\mathbf{w}) - \frac{n}{2} \log 2\pi - \frac{1}{2} \log |\mathbf{K}(\mathbf{X}, \mathbf{X}') + \mathbf{I}\sigma^2| \quad (19)$$

After determining the parameters of the model, the probabilistic prediction of new values y_{new} for a new input vector x_{new} can take place as follows:

$$P(y_{new}|\mathbf{y}, \mathbf{X}, \mathbf{x}) = \frac{P(y_{new}, \mathbf{y}|\mathbf{X}, \mathbf{x}_{new})}{P(\mathbf{y}|\mathbf{X}, \mathbf{x}_{new})} \quad (20)$$

where:

$$P(y_{new}|\mathbf{y}, \mathbf{X}, \mathbf{x}_{new}) = \iint P(y_{new}|f_{new}, x_{new}) P(\mathbf{f}|\mathbf{y}, \mathbf{X}) P(f_{new}|\mathbf{f}, \mathbf{X}, \mathbf{x}_{new}) d\mathbf{f} df_{new} \quad (21)$$

The individual components of the above integral can be represented as follows:

$$P(y_{new}|f_{new}, x_{new}) = N(y_{new}|\mathbf{h}(\mathbf{x}_{new})^T \mathbf{w} + f_{new}, \sigma_{new}^2) \quad (22)$$

$$P(\mathbf{f}|\mathbf{y}, \mathbf{X}) = N\left(\mathbf{f} \left| \frac{1}{\sigma^2} \left(\frac{\mathbf{I}}{\sigma^2} + \mathbf{K}(\mathbf{X}, \mathbf{X}') \right)^{-1} (\mathbf{y} - \mathbf{H}\mathbf{w}), \left(\frac{\mathbf{I}}{\sigma^2} + \mathbf{K}(\mathbf{X}, \mathbf{X}') \right)^{-1} \right.\right) \quad (23)$$

$$P(f_{new}|\mathbf{f}, \mathbf{X}, \mathbf{x}_{new}) = N\left(f_{new} | \mathbf{K}(\mathbf{x}_{new}^T, \mathbf{X}) \mathbf{K}(\mathbf{X}, \mathbf{X}')^{-1} \mathbf{f}, \Delta\right) \quad (24)$$

where:

$$\Delta = k(x_{new}, x_{new}') - \mathbf{K}(\mathbf{x}_{new}^T, \mathbf{X}) \mathbf{K}(\mathbf{X}, \mathbf{X}')^{-1} \mathbf{K}(\mathbf{X}, \mathbf{x}_{new}') \quad (25)$$

Finally the probability density of prediction y_{new} at the new point x_{new} with known \mathbf{y} and \mathbf{X} is given by the following equation:

$$P(y_{new}|\mathbf{y}, \mathbf{X}, \mathbf{x}_{new}) = N(y_{new}|\mathbf{h}(\mathbf{x}_{new})^T \mathbf{w} + \rho, \sigma_{new}^2 + \Sigma) \quad (26)$$

where:

$$\hat{\mathbf{n}} = \mathbf{K}(\mathbf{x}_{new}^T, \mathbf{X}) (\mathbf{K}(\mathbf{X}, \mathbf{X}') + \mathbf{I}\sigma^2)^{-1} (\mathbf{y} - \mathbf{H}\mathbf{w}) \quad (27)$$

$$\Sigma = k(x_{new}, x_{new}') - \mathbf{K}(\mathbf{x}_{new}^T, \mathbf{X}) (\mathbf{K}(\mathbf{X}, \mathbf{X}') + \mathbf{I}\sigma^2)^{-1} \mathbf{K}(\mathbf{X}, \mathbf{x}_{new}') \quad (28)$$

3.4. Variable importance

Variable importance is the technique which allows for the determination of the significance of each explanatory variable in reference to its effect on the implemented machine learning model [34,62]. This concept consists of the determination of the model error by permutations of the values of each variable. The given variable is significant if changes in its value cause changes in the model error, as the model relied on this variable for prediction. If the permutations of the variable do not cause changes in the model error, then it is considered insignificant. In other words, the more the model relies on a variable to make predictions, the more important it is for the model. The values of significance of the variables are determined on the basis of algorithm 2.

3.5. Accumulated local effects

Accumulated local effects (ALE) is the method which allows for the assessment of the relationship between the explanatory variables of the model and the predicted value [1,34]. This concept is based on conditional variable distributions. This means that mean differences in prediction and not their mean values are taken into account (as is the case with the partial dependence (PD) concept [34]). ALE reflects the way in which model forecasts change within the narrow range of values of variables. This method is particularly useful in the case of sets whose parameters are correlated with each other. The ALE function is defined as follows:

$$ALE(x_1) = \int_{\min(x_1)}^{x_1} E \left[\frac{\partial f(x_1, x_2)}{\partial x_1} \Big|_{x_1 = z_1} \right] dz_1 + c_1 = \int_{\min(x_1)}^{x_1} \int p(x_2|z_1) \frac{\partial f(z_1, x_2)}{\partial z_1} dx_2 dz_1 + c_1 \quad (29)$$

where partial derivative $\frac{\partial f(x_1, x_2)}{\partial x_1}$ represents the local effect of x_1 on prediction function f at (x_1, x_2) , $\min(x_1)$ is lower value of considered variable range, c_1 is a constant selected in order to vertically center the graph.

Averaging the local effect over the conditional distribution $p(x_2|x_1)$ makes it possible to separate the effect of other correlated variables located outside the considered range of values of variable x_1 .

In order to determine local effects, the whole range of values of the given explanatory variable must be divided into multiple intervals. The "effect" is understood as the difference in prediction calculated separately for each occurrence of a variable in a given interval. All differences in the given interval are summed up and divided by the number of occurrences – this way, the obtained mean difference in predictions is the "local" effect. Ultimately the value of the accumulated local effect of a given variable is determined by summing up all the local effects and represents the average change in the prediction when the value of the variable changes within its range.

Algorithm 2: Variable importance determination

Input:

X – variables matrix (explanatory variables)
 y – vector of predicted values of original data
 f – trained model
 $L(y, f)$ – loss function (any model performance method)

Steps:

1. Compute the original model error $L^0 = L(y, f(X))$
2. For each explanatory variable X_j :
 - a. In order to break the relationship between variable X_j and true prediction y – generate feature matrix X^p by permuting variable X_j in the data X .
 - b. Compute model predictions Y based on the permuted data
 - c. Calculate error based on the predictions of the permuted data $L_j = L(Y, f(X^p))$.
 - d. Calculate variable importance $VI_j = L_j - L^0$
3. Sort explanatory variables by descending VI

Output:

VI_j – variable importance of each explanatory variable

Numerically, ALE for a single variable can be calculated according to the following relationship:

$$ALE(x_1) = \sum_{k=1}^{k(x_1)} \frac{1}{n(k)} \sum_{i: x_1^{(i)} \in N(k)} [f(z_k, x_1^{(i)}) - f(z_{k-1}, x_1^{(i)})] - c_1 \quad (30)$$

where z_k represents the boundary of the range of variable x_1 , $N(k)$ is the interval $[z_{k-1}, z_k)$, $k(x_1)$ is the index of the interval to which a given point of variable x_1 belongs, $n(k)$, means the number of points within the interval under consideration, and f is the prediction function.

The ALE method also allows for analysis of changes in the predicted value in the case of interaction of two (ALE second-order) or more variables (ALE higher-order). In this case, the main impact of the variables concerned is ignored – only the effect of their interaction is calculated. For two explanatory variables, the ALE function may be represented as:

$$ALE(x_1, x_2) = \int_{\min(x_1)}^{x_1} \int_{\min(x_2)}^{x_2} E \left[\frac{\partial f(x_1, x_2, x_{\{1,2\}})}{\partial x_1 \partial x_2} \Big|_{x_1 = z_1, x_2 = z_2} \right] dz_1 dz_2 \quad (31)$$

and in the numerical form, the above relationship may be presented as follows:

$$ALE(x_1, x_2) = \sum_{k=1}^{k(x_1)} \sum_{m=1}^{k(x_2)} \frac{1}{n_{\{1,2\}}(k, m)} \sum_{i: x_{\{1,2\}}^{(i)} \in N(k, m)} \Delta f_{1,2}(K, k, m, x_{\{1,2\}}^{(i)}) \quad (32)$$

where:

$$\Delta f_{1,2}(K, k, m, x_{\{1,2\}}^{(i)}) = \left[f(z_{k,1}, z_{m,2}, x_{\{1,2\}}^{(i)}) - f(z_{k-1,1}, z_{m,2}, x_{\{1,2\}}^{(i)}) \right] - \left[f(z_{k,1}, z_{m-1,2}, x_{\{1,2\}}^{(i)}) - f(z_{k-1,1}, z_{m-1,2}, x_{\{1,2\}}^{(i)}) \right] \quad (33)$$

The rules for the determination of ALE for two variables are identical to those for one variable, whereby, the intervals are replaced by rectangular areas due to the necessity of accumulation of local effects

in two dimensions. ALE can also be calculated for the interaction of three or more variables – the relevant relationship can be found in paper [1].

4. Results and discussion

The input parameters of the model were the cyclic operating parameters: the average LIC temperature during the full duty cycle (T_c), the value of current during the discharge half-cycle (I_d), depth of discharge (DoD), the value of mean current during the charge half-cycle ($I_{ch, avg}$). The total aging processes leading to LIC degradation were included in the model by the number of full equivalent cycles (FEC). The predicted value was the relative useful energy (RUE_c) throughput of a cell during a full duty cycle.

4.1. Model training

The results of measurements of cycling of LICs, which were cycled with $DoD > 70\%$ (20 LICs in total), were used as the learning dataset. Cells "A38", "B32", "B40" and "H9" were used to verify the model exclusively. Finally, the learning dataset contained 311 samples, and the verification set consisted of 99 samples – a fragment of the learning dataset after initial calculations is presented in Table III. The value of $FEC=0$ is equivalent to $SOH=100\%$ of the cell, while the last value of $FEC=533$ indicates $SOH=80\%$ and the accomplishment of the EoL status.

As the kernel function of the GPR model, the matern 3/2 function was used, which is expressed by the following equation:

$$k_{mat3/2}(x, x') = \sigma_f^2 \left(1 + \frac{\sqrt{3}r}{\sigma_l} \right) \exp \left(-\frac{\sqrt{3}r}{\sigma_l} \right) \quad (34)$$

where r is Euclidean distance between x and x' .

TABLE III
SAMPLE OF LEARNING DATASET – CELL „A23”

T_c (°C)	I_d (A)	DoD (%)	$I_{ch, avg}$ (A)	FEC (-)	RUE_c (-)
36.6	-7.8	100	1.74	0	0.905
36.6	-7.8	100	1.74	41	0.871
⋮	⋮	⋮	⋮	⋮	⋮
36.6	-7.8	100	1.74	504	0.371
36.6	-7.8	100	1.74	533	0.221

The values of characteristic parameters σ_f and σ_l were determined using the method of optimisation without constraints (quasi-Newton) and were 0.1687 and 0.7659 respectively, while the value of the logarithmic membership function was $L=713.7$. The linear function type was adopted for the function set $h(x)$. The coefficient of determination R^2 , mean average percentage error $MAPE$ and root mean square error $RMSE$ were used to assess the model quality. The above indicators are determined according to the following relationships:

$$R^2 = \frac{\sum_{i=1}^n (f_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (35)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - f_i}{y_i} \right| \cdot 100\% \quad (36)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - f_i)^2} \quad (37)$$

where n is the number of samples, f is the predicted value, y is the measured value.

The results of the learning process were compared with three supervised machine learning models: a regression tree, a support vector machine (*SVM*), and an ensemble of regression trees and are summarized in Table IV. The same input parameter structure was used for each model, and the predictor parameter was RUE_c . For the regression tree, the lowest $RMSE$ was achieved for a leaf size of 4. It was observed that increasing the leaf size beyond this value resulted in an increase in $RMSE$. For the *SVM*-based model, the lowest $RMSE$ was obtained for a Gaussian-type kernel with a characteristic length of 0.56. The model with second lowest $RMSE$ was the ensemble of the regression trees consisting of a combination of 100 trees with a leaf size of 5 each and a learning rate of 0.25.

The example characteristics of the three observed types of RUE_c evolution for two models with lowest $RMSE$ (*GPR* model and Ensemble of trees model) are presented in Fig. 5 (a-c). The learning results of other LICs for all comparative models are included in Appendix A.

As opposed to the model based on Ensemble of regression trees, the response of the *GPR* model for each LIC included in the learning dataset was within the assumed confidence interval (95%). The *MAPE* of the *GPR* model developed for all samples of the learning dataset was 0.05%. This proves that the *GPR* model almost perfectly matches the learning dataset.

4.2. Prediction

The developed original model was verified using new load profiles which were not used to train the model. LICs with different mean

TABLE IV
LEARNING PROCEDURE – SUMMARY OF RESULTS FOR DIFFERENT MODELS

Model	MAPE (%)	R ² (-)	RMSE (-)
Ensemble of trees	0.73	0.95	0.0311
<i>GPR</i>	0.05	0.99	0.0141
Regression tree	3.54	0.85	0.0551
<i>SVM</i>	2.72	0.89	0.0465

cycling temperatures (T_c) at mean load current of $I_d = -5.2$ A were selected for verification. For instance, for $T_c > 40^\circ\text{C}$, the learning dataset included LICs loaded with $I_d = -2.6$ A and $I_d = -7.8$ A (cells "D6" and "H12"), therefore, the "A38" cell was selected for verification at higher temperatures. The verification process consisted of the RUE_c prediction by a model of 4 cells in the period between *BoL* and *EoL*, and of comparison of their values obtained during the experiment. The verification results are presented in Table V, and the characteristics for the 4 tested cases are presented in Fig. 6. From the results obtained it can be observed that in two cases ("H9" and "B40") *APE* exceeded 5%. The reason for obtaining higher *APE* for the indicated LICs is primarily due to the low number of samples in the learning dataset containing conditions similar to those under which they were cycled. For the "H9" LIC the problem is in the near *EoL* phase. During the charging half-cycle, the average charging current for this LIC was 2.85 A. The learning dataset contains 29 samples (9.3% of all samples) with similar values of cycling parameters (especially with high average charging currents) to "H9" cell. Cell "B40" performed a high number of *FECs* (over 1000) while in the learning dataset only 7% of all samples are with similar values (mainly coming from "C26" LIC, which performed 909 *FEC*). This compares to 14.1% of samples

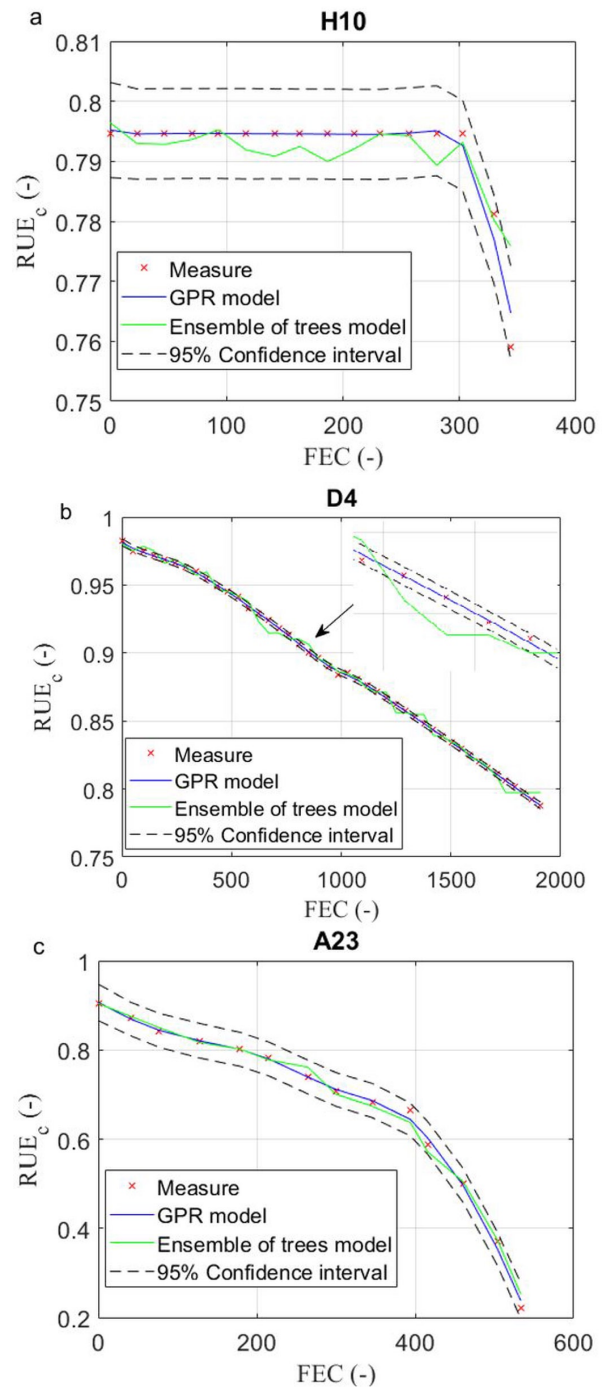


Fig. 5. Learning results obtained for three observed types of RUE_c evolution of *GPR* model and Ensemble of regression trees: a) after about 300 *FECs*, the cell lost the ability to transfer the fixed energy – the phase of significant decrease in RUE_c takes place, b) under these conditions, throughout the lifetime of the LIC, the decrease in RUE_c was approximately linear, c) the phase of slow degradation occurs until approximately 400 *FECs* are completed, then it is possible to observe the phase of accelerated ability to transfer RUE_c

with similar values in the learning dataset for cell "A38" and 14.5% for "B32".

In the author's opinion, the obtained results of the verification process confirm the effectiveness of the selected *GPR* method for the purpose of RUE_c prediction which a LIC can transfer during a full duty cycle throughout its life. Only in one test case did the *MAPE* slightly exceed 5% (the "B40" cell). Also in favor of the method used, is the fact that despite an almost ideal matching of the model to the learning data, the prediction of RUE_c under new operating conditions for the LIC is possible with little error.

The GPR model also allows for prediction within ranges exceeding the ranges of variables of the learning dataset, which is not possible for some techniques based on artificial intelligence – for instance, neural networks or fuzzy logic.

4.3. Model explanation

In order to determine the significance of the explanatory variables of the model, the variable importance (VI) technique was used. *RMSE* was selected as the loss function of *L* model (eq. 37). The calculations were repeated 8 times in order to negate the effect of uncertainty caused by permutations of values. The obtained results of VI are characterized by a low standard deviation; they were averaged and listed in Table VI. Based on the results, the respective model input parameters were ordered in terms of their significance - the effect of *FEC* on the predicted value of *RUE_c* is the highest in the used dataset (the highest VI), then the effect of *I_d* and *T_c* is on a comparable level. From among the adopted model parameters, *DoD* and *I_{ch_avg}* have the lowest effect on *RUE_c* (in both cases the calculated significance is at a similar level).

Given the fact that interpretation of the structure of the developed GPR non-parametric model is very difficult, in order to determine the effect which the respective model parameters have on the value of

TABLE V
RESULTS OF VERIFICATION PROCEDURE ON NEW LOAD PROFILES

Cell ID	<i>T_c</i> (°C)	<i>I_d</i> (A)	<i>DoD</i> (%)	<i>I_{ch_avg}</i> (A)	<i>MAPE</i> (%)
B40	30.3	-5.2	100	2.2	5.63
H9	35.3	-2.6	100	2.85	2.88
A38	54.6	-5.2	100	2.63	2.77
B32	39.7	-5.2	100	2.47	3.26




Fig. 6. Results of the model verification procedure

TABLE VI
VALUES OF VARIABLES IMPORTANCE OF IMPLEMENTED MODEL

Parameter	<i>T_c</i> (°C)	<i>I_d</i> (A)	<i>DoD</i> (%)	<i>I_{ch_avg}</i> (A)	<i>FEC</i> (-)
mean <i>VI</i>	0.120042	0.147175	0.048705	0.056989	0.167583
std. dev.	0.001375	0.001651	0.000866	0.000554	0.001614

the *RUE_c* prediction, the author has applied the ALE concept. Fig. 7 (a-e) presents the plots of the first-order accumulated local effects which determine the impact of individual input parameters of the GPR model on *RUE_c*. The value of ALE at the given point determines the difference in prediction in relation to the mean prediction of *RUE_c*. ALE=0 represents the mean prediction of *RUE_c*. For instance, for *T_c* ≈ 25°C, the *RUE_c* prediction will be lower by 0.05 in relation to the mean prediction which is an exclusive consequence of temperature (the effect of other cyclic operating parameters is separated). Based

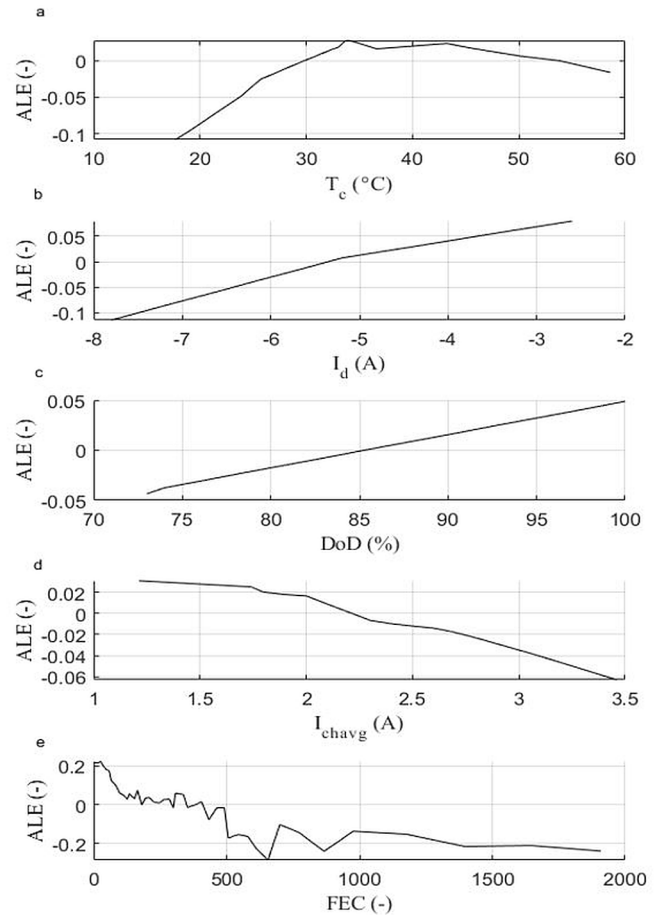


Fig. 7. First-order ALE plots for individual model input parameters: a) average temperature of LIC during the full cycle b) discharge current c) depth of discharge d) average charge current e) full equivalent cycle.

on the results obtained, it is possible to determine, unambiguously, the effect of *T_c* on *RUE_c* – the lowest values of *RUE_c* are obtained at average cycling temperatures below 30°C and they increase gradually up to the range of values between 30°C and 44°C, where *RUE_c* reaches its peak value and then falls for *T_c* higher than 44°C (Fig. 7 – a). In the case of values of currents *I_d* and *I_{ch_avg}*, the effect on *RUE_c* is linear. The lower the values of *I_d* and *I_{ch_avg}* are, the higher the *RUE_c* is. Furthermore, cycling of the LICs at *I_d* values lower than -5.2 A and higher than 2.25 A for *I_{ch_avg}* will result in lower *RUE_c* values over their lifetime – the visible breaking point of characteristics (Fig. 7 – b, d). The plot of ALE for *DoD* showed the linear dependence of this factor on *RUE_c* (Fig. 7 – c). The amount of transferred *RUE_c* drops sharply when the cells complete more than 500 full equivalent duty cycles (Fig. 7 – e).

Additionally, the results obtained using the ALE method confirm the results obtained using the VI technique – the highest dispersion of ALE values (from -0.286 to 0.225) is characteristic of *FEC*, which is compliant with the highest value of VI for this parameter. For *I_d* and *T_c* the differences in relation to the mean prediction vary from -0.114 to 0.08 for *I_d* and from -0.108 to 0.027 for *T_c* respectively, which also correlates with the VI results. The lowest dispersion of values was observed for *I_{ch_avg}* – from -0.063 to 0.031, which means the lowest effect on *RUE_c* in the used dataset.

In order to determine the effect of interaction of the model parameters on *RUE_c*, the values of the second-order accumu-

lated local effects were determined in the paper for all the possible combinations of pairs of the GPR model input parameters. The results obtained in the form of value maps are presented in Fig. 8 (a–j). Analysis of the interaction effect of model parameter pairs showed that the highest influence on RUE_c is exerted by combinations of the following pairs T_c – FEC , I_d – FEC and I_{ch_avg} – FEC . For instance, for LICs, which completed a large number of $FECs$ (over 1500) at T_c below 25°C, the differences in relation to the mean RUE_c prediction even amount to -0.4, and at T_c above 50°C +0.2 respectively (Fig. 8 a). A high level of influence was also shown by the I_{ch_avg} – FEC pair at around $FEC=1350$ and $I_{ch_avg}=3A$ – the ALE value in this area reaches up to +0.3 (Fig. 8 d). The level of influence of the DoD – FEC pair over the entire value range does not exceed the range between -0.04 and +0.06 (Fig. 8 d). To sum up – the pairs containing FEC are characterised by the highest influence due to the highest effect of FEC on RUE_c which is shown in Fig. 7 – e. The interaction effect of parameter pairs, i.e. T_c – DoD and T_c – I_d is locally at the level of hundredths (+0.02 and -0.015) – Fig. 8 – h,j. On the other hand, the effect of other pairs is at a negligible level (ALE at a level of thousandths or lower) – Fig. 8 – e-g,i.

5. Conclusion

The paper presents the author’s prediction model for the useful energy that can be transferred during a single duty cycle under various temperature and load conditions, taking into account the energy throughput to date by $LiNi_{0.33}Mn_{0.33}Co_{0.33}O_2$ cells.

APPENDIX

A. Results of the learning procedure – $MAPE$ of comparative models for individual LICs.

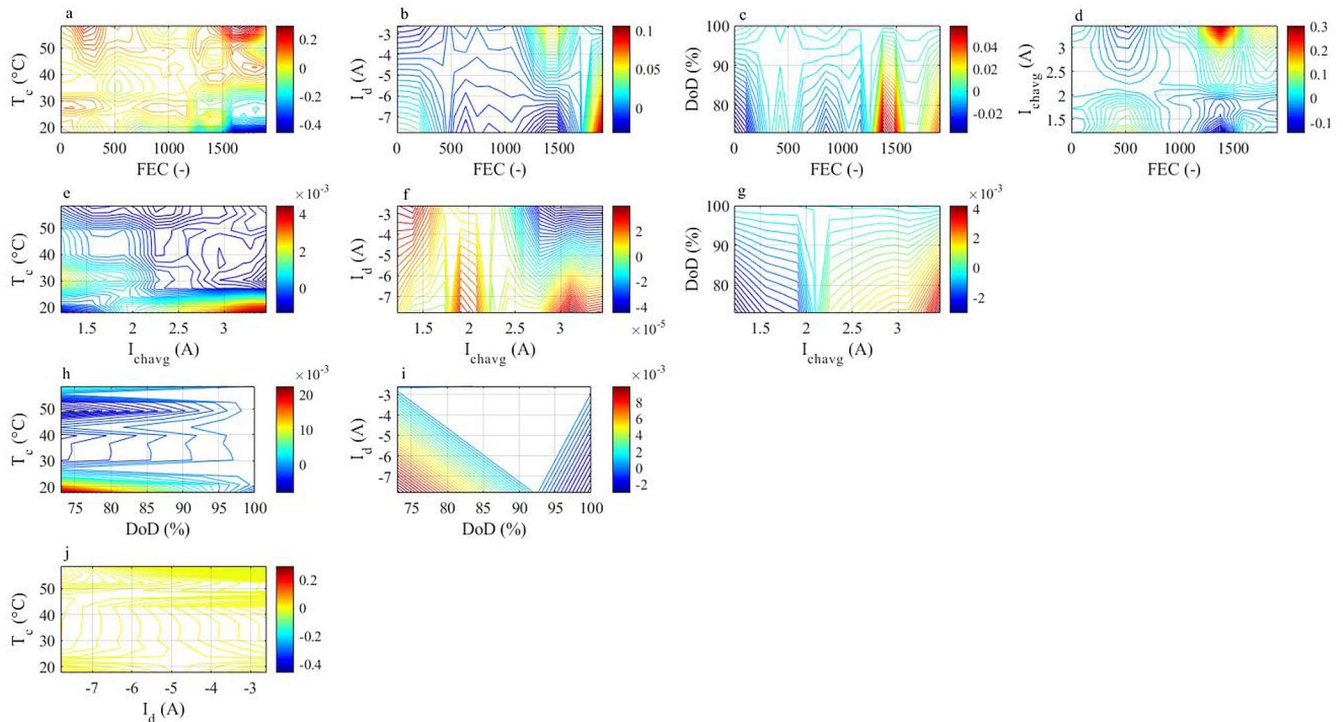


Fig. 8. Plots of accumulated local effects of the second order for the respective combinations of pairs of model input parameters

The methodology presented in the paper allows for the obtaining of a RUE_c prediction over the entire LIC life with high accuracy, even when learning datasets with a small number of samples are used. The developed model is resistant to the overfitting phenomenon – despite an almost ideal matching of the model to the learning dataset used, the prediction of trends in the evolution of RUE_c is possible under new load and temperature conditions, which has been confirmed by the author with 4 test cases. The appropriate selection of types for the kernel function $k(x, x')$ and basis functions $h(x)$ was critical to achieving the high accuracy of model prediction.


In comparison to classic modelling techniques, the advantage is that the model structure does not need to be specified. In fact, this is the disadvantage of methods based on machine learning – the structures of such models and their parameters have no physical meaning. The author proposes a solution for the above-mentioned problem by using the XAI techniques, which enable determination of both the significance of model input parameters, and the quantitative determination of their effect on the predicted value of RUE_c .

The information obtained in this way may be used, among other things, to improve the algorithms used specifically in battery or battery pack management systems, helping to optimise their operation and extend their life. What is more, the methodology proposed by the author can be applied to electrochemical cells with different chemical compositions.

References

1. Apley D W, Zhu J. Visualizing the effects of predictor variables in black box supervised learning models. *Journal of the Royal Statistical Society. Series B: Statistical Methodology* 2020; 82(4): 1059-1086, <https://doi.org/10.1111/rssb.12377>.
2. Belt J, Utgikar V, Bloom I. Calendar and PHEV cycle life aging of high-energy, lithium-ion cells containing blended spinel and layered-oxide cathodes. *Journal of Power Sources* 2011; 196(23): 10213-10221, <https://doi.org/10.1016/j.jpowsour.2011.08.067>.
3. Bloom I, Cole B W, Sohn J J et al. An accelerated calendar and cycle life study of Li-ion cells. *Journal of Power Sources* 2001; 101(2): 238-247, [https://doi.org/10.1016/S0378-7753\(01\)00783-2](https://doi.org/10.1016/S0378-7753(01)00783-2).
4. Broussely M, Biensan P, Bonhomme F et al. Main aging mechanisms in Li ion batteries. *Journal of Power Sources* 2005; 146(1-2): 90-96, <https://doi.org/10.1016/j.jpowsour.2005.03.172>.
5. Burzyński D, Kasprzyk L. A novel method for the modeling of the state of health of lithium-ion cells using machine learning for practical applications. *Knowledge-Based Systems* 2021; 219: 106900, <https://doi.org/10.1016/j.knosys.2021.106900>.
6. Burzyński D, Pietracho R, Kasprzyk L, Tomczewski A. Analysis and Modeling of the Wear-Out Process of a Lithium-Nickel-Manganese-Cobalt Cell during Cycling Operation under Constant Load Conditions. *Energies* 2019; 12(20): 3899, <https://doi.org/10.3390/en12203899>.
7. Chen Z, Ren Y, Jansen A N et al. New class of nonaqueous electrolytes for long-life and safe lithium-ion batteries. *Nature Communications* 2013; 4: 1-8, <https://doi.org/10.1038/ncomms2518>.
8. Diao W, Saxena S, Pecht M. Accelerated cycle life testing and capacity degradation modeling of LiCoO₂-graphite cells. *Journal of Power Sources* 2019; 435(June): 226830, <https://doi.org/10.1016/j.jpowsour.2019.226830>.
9. Dong G, Zhang X, Zhang Ch, Chen Z. A method for state of energy estimation of lithium-ion batteries based on neural network model. *Energy* 2015; 90(1)1:879-888, <https://doi.org/10.1016/j.energy.2015.07.120>.
10. dos Reis G, Strange C, Yadav M, Li S. Lithium-ion battery data and where to find it. *Energy and AI* 2021, <https://doi.org/10.1016/j.egyai.2021.100081>.
11. Dudézert C, Reynier Y, Duffault J M, Franger S. Fatigue damage approach applied to Li-ion batteries ageing characterization. *Materials Science and Engineering B: Solid-State Materials for Advanced Technology* 2016; 213: 177-189, <https://doi.org/10.1016/j.mseb.2016.04.017>.
12. Ecker M, Gerschler J B, Vogel J et al. Development of a lifetime prediction model for lithium-ion batteries based on extended accelerated aging test data. *Journal of Power Sources* 2012; 215: 248-257, <https://doi.org/10.1016/j.jpowsour.2012.05.012>.
13. Edström K, Dominko R, Fichtner M et al. BATTERY 2030+ Roadmap. 2020: 83, <https://doi.org/10.33063/diva2-1452023>.
14. El Mejdoubi A, Chaoui H, Gualous H et al. Lithium-ion batteries health prognosis considering aging conditions. *IEEE Transactions on Power Electronics* 2019; 34(7): 6834-6844, <https://doi.org/10.1109/TPEL.2018.2873247>.
15. Gao Y, Jiang J, Zhang C et al. Lithium-ion battery aging mechanisms and life model under different charging stresses. *Journal of Power Sources* 2017; 356: 103-114, <https://doi.org/10.1016/j.jpowsour.2017.04.084>.
16. Han X, Ouyang M, Lu L, Li J. A comparative study of commercial lithium ion battery cycle life in electric vehicle: Capacity loss estimation. *Journal of Power Sources* 2014; 268: 658-669, <https://doi.org/10.1016/j.jpowsour.2014.06.111>.
17. Hasib S A, Islam S, Chakraborty R K et al. A Comprehensive Review of Available Battery Datasets, RUL Prediction Approaches, and Advanced Battery Management. *IEEE Access* 2021; 9: 86166-86193, <https://doi.org/10.1109/ACCESS.2021.3089032>.
18. Haykin S, Simon S. *Neural Networks and learning machines*. Prentice Hall; New York 2009.
19. How D N T, Hannan M A, Lipu M S H et al. State-of-Charge Estimation of Li-Ion Battery in Electric Vehicles: A Deep Neural Network Approach. *IEEE Transactions on Industry Applications* 2020; 56(5): 5565-5574, <https://doi.org/10.1109/TIA.2020.3004294>.
20. Hu X, Jiang J, Cao D, Egardt B. Battery health prognosis for electric vehicles using sample entropy and sparse Bayesian predictive modeling. *IEEE Transactions on Industrial Electronics* 2016; 63(4): 2645-2656.
21. Kasprzyk L. Modelling and analysis of dynamic states of the lead-acid batteries in electric vehicles. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2017; 19(2): 229-236, <https://doi.org/10.17531/ein.2017.2.10>.
22. Kasprzyk L, Domeracka A, Burzyński D. Modelowanie pracy i trwałości akumulatorów litowo-jonowych w pojazdach elektrycznych. *Przegląd Elektrotechniczny* 2018; 1(12): 160-163, <https://doi.org/10.15199/48.2018.12.34>.
23. Keil P, Schuster S F, Wilhelm J et al. Calendar Aging of Lithium-Ion Batteries. *Journal of The Electrochemical Society* 2016; 163(9): A1872-A1880, <https://doi.org/10.1149/2.0411609jes>.
24. Li I H, Wang W Y, Su S F, Lee Y S. A merged fuzzy neural network and its applications in battery state-of-charge estimation. *IEEE Transactions on Energy Conversion* 2007; 22(3): 697-708, <https://doi.org/10.1109/TEC.2007.895457>.
25. Li K, Wei F, Tseng K J, Soong B H. A Practical Lithium-Ion Battery Model for State of Energy and Voltage Responses Prediction Incorporating Temperature and Ageing Effects. *IEEE Transactions on Industrial Electronics* 2018; 65(8): 6696-6708, <https://doi.org/10.1109/TIE.2017.2779411>.
26. Li X, Miao J, Ye J. Lithium-ion battery remaining useful life prediction based on grey support vector machines. *Advances in Mechanical Engineering* 2015; 7(12): 1-8, <https://doi.org/10.1177/1687814015622327>.
27. Li X, Pan K, Fan G et al. A physics-based fractional order model and state of energy estimation for lithium ion batteries. Part II: Parameter identification and state of energy estimation for LiFePO₄ battery. *Journal of Power Sources* 2017; 367: 202-213, <https://doi.org/10.1016/j.jpowsour.2017.09.048>.
28. Li Y, Liu K, Foley A M et al. Data-driven health estimation and lifetime prediction of lithium-ion batteries: A review. *Renewable and Sustainable Energy Reviews* 2019. doi:10.1016/j.rser.2019.109254, <https://doi.org/10.1016/j.rser.2019.109254>.
29. Li Y, Li K, Liu X, Zhang L. Fast battery capacity estimation using convolutional neural networks. *Transactions of the Institute of Measurement and Control* 2020, <https://doi.org/10.1177/0142331220966425>.
30. Liu G, Ouyang M, Lu L et al. A highly accurate predictive-adaptive method for lithium-ion battery remaining discharge energy prediction in electric vehicle applications. *Applied Energy* 2015; 149: 297-314, <https://doi.org/10.1016/j.apenergy.2015.03.110>.
31. Liu K, Li Y, Hu X et al. Gaussian Process Regression with Automatic Relevance Determination Kernel for Calendar Aging Prediction of Lithium-Ion Batteries. *IEEE Transactions on Industrial Informatics* 2020; 16(6): 3767-3777, <https://doi.org/10.1109/TII.2019.2941747>.
32. Liu K, Shang Y, Ouyang Q, Widanage W D. A Data-Driven Approach with Uncertainty Quantification for Predicting Future Capacities and Remaining Useful Life of Lithium-ion Battery. *IEEE Transactions on Industrial Electronics* 2021; 68(4): 3170-3180, <https://doi.org/10.1109/TIE.2020.2973876>.

33. Liu T, Cheng L, Pan Z, Sun Q. Cycle life prediction of lithium-ion cells under complex temperature profiles. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2016; 18(1): 25-31, <https://doi.org/10.17531/ein.2016.1.4>.
34. Molnar C. Interpretable Machine Learning. A Guide for Making Black Box Models Explainable. Book 2019: 247.
35. Motapon S N, Lachance E, Dessaint L-A, Al-Haddad K. A Generic Cycle Life Model for Lithium-Ion Batteries Based on Fatigue Theory and Equivalent Cycle Counting. *IEEE Open Journal of the Industrial Electronics Society* 2020; 1(August): 207-217, <https://doi.org/10.1109/OJIES.2020.3015396>.
36. Naumann M, Spingler F, Jossen A. Analysis and modeling of cycle aging of a commercial LiFePO₄/graphite cell. *Journal of Power Sources* 2020; 451(December 2019): 227666, <https://doi.org/10.1016/j.jpowsour.2019.227666>.
37. Ning G, Popov B N. Cycle Life Modeling of Lithium-Ion Batteries. *Journal of The Electrochemical Society* 2004; 151(10): A1584, <https://doi.org/10.1149/1.1787631>.
38. Olmos J, Gandiaga I, Saez-de-Ibarra A et al. Modelling the cycling degradation of Li-ion batteries: Chemistry influenced stress factors. *Journal of Energy Storage* 2021; 40(May): 102765, <https://doi.org/10.1016/j.est.2021.102765>.
39. Pan R, Wang Y, Zhang X et al. Power capability prediction for lithium-ion batteries based on multiple constraints analysis. *Electrochimica Acta* 2017; 238: 120-133, <https://doi.org/10.1016/j.electacta.2017.04.004>.
40. Pielecha I, Cieřlik W, Szalek A. Operation of electric hybrid drive systems in varied driving conditions. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2018; 20(1): 16-23, <https://doi.org/10.17531/ein.2018.1.3>.
41. Pietracho R, Wenge C, Balischewski S et al. Potential of Using Medium Electric Vehicle Fleet in a Commercial Enterprise Transport in Germany on the Basis of Real-World GPS Data. *Energies* 2021; 14(17): 1-23, <https://doi.org/10.3390/en14175327>.
42. Rasmussen C E, Williams Ch K. Gaussian processes for machine learning. MIT press Cambridge; 2006:1, <https://doi.org/10.7551/mitpress/3206.001.0001>.
43. Richardson R R, Birkl C R, Osborne M A, Howey D A. Gaussian Process Regression for in Situ Capacity Estimation of Lithium-Ion Batteries. *IEEE Transactions on Industrial Informatics* 2019; 15(1): 127-138, <https://doi.org/10.1109/TII.2018.2794997>.
44. Richardson R R, Osborne M A, Howey D A. Battery health prediction under generalized conditions using a Gaussian process transition model. *Journal of Energy Storage* 2019; 23(March): 320-328, <https://doi.org/10.1016/j.est.2019.03.022>.
45. Safari M, Morcrette M, Teyssot A, Delacourt C. Multimodal Physics-Based Aging Model for Life Prediction of Li-Ion Batteries. *Journal of The Electrochemical Society* 2009; 156(3): A145, <https://doi.org/10.1149/1.3043429>.
46. Safari M, Morcrette M, Teyssot A, Delacourt C. Life Prediction Methods for Lithium-Ion Batteries Derived from a Fatigue Approach. *Journal of The Electrochemical Society* 2010; 157(7): A892, <https://doi.org/10.1149/1.3432560>.
47. Saha B, Goebel K, Poll S, Christophersen J. Prognostics methods for battery health monitoring using a Bayesian framework. *IEEE Transactions on Instrumentation and Measurement* 2009; 58(2): 291-296, <https://doi.org/10.1109/TIM.2008.2005965>.
48. Schmalstieg J, Käbitz S, Ecker M, Sauer D U. A holistic aging model for Li(NiMnCo)O₂ based 18650 lithium-ion batteries. *Journal of Power Sources* 2014; 257: 325-334, <https://doi.org/10.1016/j.jpowsour.2014.02.012>.
49. Schulze M C, Neale N R. Half-Cell Cumulative Efficiency Forecasts Full-Cell Capacity Retention in Lithium-Ion Batteries. *ACS Energy Letters* 2021; 6(3): 1082-1086, <https://doi.org/10.1021/acscenergylett.1c00173>.
50. Sikha G, Popov B N, White R E. Effect of Porosity on the Capacity Fade of a Lithium-Ion Battery. *Journal of The Electrochemical Society* 2004; 151(7): A1104, <https://doi.org/10.1149/1.1759972>.
51. Su C, Chen H, Wen Z. Prediction of remaining useful life for lithium-ion battery with multiple health indicators. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2021; 23(1): 176-183, <https://doi.org/10.17531/ein.2021.1.18>.
52. Tagade P, Hariharan K S, Ramachandran S et al. Deep Gaussian process regression for lithium-ion battery health prognosis and degradation mode diagnosis. *Journal of Power Sources* 2020; 445(October 2019): 227281, <https://doi.org/10.1016/j.jpowsour.2019.227281>.
53. Tao L, Ma J, Cheng Y et al. A review of stochastic battery models and health management. *Renewable and Sustainable Energy Reviews* 2017; 80(February 2018): 716-732, <https://doi.org/10.1016/j.rser.2017.05.127>.
54. Vetter J, Novák P, Wagner M R et al. Ageing mechanisms in lithium-ion batteries. *Journal of Power Sources* 2005; 147(1-2): 269-281, <https://doi.org/10.1016/j.jpowsour.2005.01.006>.
55. Vidal C, Malysz P, Kollmeyer P, Emadi A. Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art. *IEEE Access* 2020; 8: 52796-52814, <https://doi.org/10.1109/ACCESS.2020.2980961>.
56. Wang A, Kadam S, Li H et al. Review on modeling of the anode solid electrolyte interphase (SEI) for lithium-ion batteries. *npj Computational Materials* 2018, <https://doi.org/10.1038/s41524-018-0064-0>.
57. Wang J, Liu P, Hicks-Garner J et al. Cycle-life model for graphite-LiFePO₄ cells. *Journal of Power Sources* 2011; 196(8): 3942-3948, <https://doi.org/10.1016/j.jpowsour.2010.11.134>.
58. Wang J, Purewal J, Liu P et al. Degradation of lithium ion batteries employing graphite negatives and nickel e cobalt e manganese oxide b spinel manganese oxide positives : Part 1 , aging mechanisms and life estimation. *Journal of Power Sources* 2014; 269: 937-948, <https://doi.org/10.1016/j.jpowsour.2014.07.030>.
59. Wang Y, Zhang C, Chen Z. A method for joint estimation of state-of-charge and available energy of LiFePO₄ batteries. *Applied Energy* 2014; 135: 81-87, <https://doi.org/10.1016/j.apenergy.2014.08.081>.
60. Wang Y, Zhang C, Chen Z. Model-based state-of-energy estimation of lithium-ion batteries in electric vehicles. *Energy Procedia* 2016; 88: 998-1004, <https://doi.org/10.1016/j.egypro.2016.06.125>.
61. Wang Y, Zhang C, Chen Z. An adaptive remaining energy prediction approach for lithium-ion batteries in electric vehicles. *Journal of Power Sources* 2016; 305: 80-88, <https://doi.org/10.1016/j.jpowsour.2015.11.087>.
62. Wei P, Lu Z, Song J. Variable importance analysis: A comprehensive review. *Reliability Engineering and System Safety* 2015; 142: 399-432, <https://doi.org/10.1016/j.res.2015.05.018>.
63. Weng C, Cui Y, Sun J, Peng H. On-board state of health monitoring of lithium-ion batteries using incremental capacity analysis with support vector regression. *Journal of Power Sources* 2013; 235: 36-44, <https://doi.org/10.1016/j.jpowsour.2013.02.012>.
64. Werner D, Paarmann S, Wetzel T. Calendar aging of li-ion cells-experimental investigation and empirical correlation. *Batteries* 2021, <https://doi.org/10.3390/batteries7020028>.
65. Wik T, Fridholm B, Kuusisto H. Implementation and robustness of an analytically based battery state of power. *Journal of Power Sources* 2015; 287: 448-457, <https://doi.org/10.1016/j.jpowsour.2015.03.165>.



A novel method for the modeling of the state of health of lithium-ion cells using machine learning for practical applications

Damian Burzyński*, Leszek Kasprzyk

Poznan University of Technology, Faculty of Control, Robotics and Electrical Engineering, ul.Piotrowo 3A, 60-965, Poznań, Poland



ARTICLE INFO

Article history:

Received 30 October 2020
Received in revised form 18 February 2021
Accepted 22 February 2021
Available online 26 February 2021

Keywords:

Machine learning
Battery state of health prediction
Life cycle modeling
Lithium-ion batteries
Modeling battery life

ABSTRACT

In this article, the authors propose an original method for the modeling of the state of health of cyclically operating lithium-ion batteries (LIBs), based on Gaussian process regression. This method allows for the estimation of the degradation of the LIBs during an equivalent duty cycle at various load patterns. The results of many years of research on the degradation of LIBs have been analyzed in two aspects. The first one concerned degradation under constant loads, and the second was related to degradation taking into account randomly variable loads. The conducted analyses demonstrated that the degradation process in the case of LIBs was characterised by high variability depending on the cyclic operation parameters (the charging and discharging half-cycle). Furthermore the degradation of LIBs depends, to a significant extent on the current state of health. For this reason, this parameter was taken into account in the new model, which is an improvement on the currently existing methods. The developed model has been verified by simulating the variable load of the cells during its entire lifespan – the obtained percentage prediction error margin during the whole simulation did not exceed 5%, which confirmed its practical usefulness.

© 2021 Elsevier B.V. All rights reserved.

1. Introduction

In recent years we have been witness to a dynamic increase in the popularity of electrochemical energy storages. This results both from the intensive development of electrochemical battery technology and mobile device technology (internet of things or 5G). These devices, despite their greater and greater efficiency, are characterised by a greater and greater ability to process information, and thus, the demand for electrical energy.

Electrochemical batteries are used most frequently in mobile solutions because of their high specific energy (the ability to accumulate energy per unit mass) when compared to alternative solutions [1]. This refers to systems which are characterised both by low and high demands for electricity, e.g. flashlights, smartphones or electrical vehicles.

In the solutions mentioned above, from among many different types of electrochemical cells, lithium-ion batteries (LIB) are used most frequently. The primary reason for their prevalence is their ability to rapidly transfer energy and recharge (high power density), as well as the lifespan, which can even be between 10–15 years [2].

The wide range of the admissible operating currents of these cells entails the risk of cell overheating – particularly in the case

of larger modules – and even the risk of fire. For this reason, the cells must be controlled by systems (BMS, battery management systems) which do not allow their limit operating conditions to be exceeded, and sometimes, they must also be cooled. It should also be pointed out that high currents flowing through the cells during the charging and discharging processes result in their fast aging.

Therefore, the designers of systems which work together with LIBs are forced to analyze their behavior under different operating conditions – modeling. The modeling of their operation allows for the prediction of their electrical parameters on terminals, as well as the prediction of temperatures and states of charge under different conditions. In many solutions, the modeling of the operation of batteries is also used during the operation of these systems, e.g. in order to estimate the range of an electrical vehicle or warn about emergency states [3].

Another area related to the electrochemical cells modeling is the estimation of their lifetime in relation to operating conditions (cyclic aging) and storing conditions (calendar aging). Calendar aging, expressed in units of time (years), is determined by the manufacturer for given storing conditions. This makes it relatively easy to estimate the time. Meanwhile, lifetime related to the cells operation is expressed as the operation cycles number under specified conditions (at assumed charging and discharging currents, temperature, depth of discharge, etc.). The cells operating conditions change permanently, therefore the calculation of cell life is a very complex issue that has not yet been sufficiently

* Corresponding author.

E-mail addresses: damian.burzynski@put.poznan.pl (D. Burzyński), leszek.kasprzyk@put.poznan.pl (L. Kasprzyk).

studied, especially in the case of LIBs. For this reason, this paper deals with the issue of determining the cells state of health (SOH). The measure of the state of health is the parameter (SOH) expressed as the ratio of the current cell capacity to its initial capacity (new cell), usually expressed in percentage. Most often, a cell is considered to be worn out when the SOH is below 80%.

The ability to determine the electrochemical cells lifespan is a key factor influencing the control algorithms of cell management systems (BMS) that control cooling/heating processes and algorithms in cell charging and loading systems. The lifespan is also a key factor when selecting energy storage for a given load profile. Incorrectly determining the lifetime can lead to costs related to overloading the cells and the need for their accelerated replacement (if the storage is of insufficient capacity) and costs related to their initial purchase (if the storage is of excessive capacity).

For this particular reason, this paper deals with the issue of modeling cells SOH. For this purpose, the capacity of a set of LIBs was measured at assumed parameters of cyclic operation, their lifespan was determined, and then their wear was predicted using an originally developed model based on machine learning, taking into account their wear history and the influence of current values of parameters of cyclic operation.

2. Literature background

Lifespan of electrochemical batteries is limited due to the physicochemical changes taking place in them. These changes are usually irreversible, take place both during cyclic operation and during self-discharge and can significantly affect the batteries energy efficiency. Physicochemical processes on which battery operation depends are associated with the undesirable aging processes. Among them, the most dominant are the processes related to the formation and evolution of the passive layer on the electrodes (called as solid electrolyte interface – SEI) and the phenomenon of metal particle deposition on the anode (lithium plating) [4]. Other aging processes may also occur, such as corrosion of the current terminals, particle gassing or the electrolyte decomposition. The course of the above processes may differ depending on the actual operating conditions of the battery (ambient pressure and temperature, as well as the intensity and duration of the electric field). The above-mentioned aging processes can occur at different rates and strictly depend on the values of cyclic operation parameters (related to environmental conditions, load conditions, and the actual SOH of battery). Aging of batteries may be accelerated when it is used at temperatures significantly different from nominal, as well as aside from the nominal voltage range (which directly results in an increase in the SEI layer). Operating batteries at low temperatures and charging them with high currents accelerate the lithium plating phenomenon, which results in a gradual loss of active mass of the electrodes and a reduction in the ability to transfer the charge [5]. On the other hand, too deep discharging may result in corrosion of the current collectors.

Due to the complex nature of aging processes and the fact that they can occur simultaneously so far this process of degradation has not been sufficiently investigated and detailed analysis is not possible during the battery life. For practical applications, two parameters are most frequently used that enable the analysis of battery SOH (without interfering with its internal structure) – capacity or internal resistance [6].

Issues related to SOH modeling are currently being addressed in many research centers all over the world. The modeling of the state of health of the LIB is most frequently based on the results of experimental data obtained using measuring equipment dedicated to working with electrochemical cells, in combination

with a climatic chamber in order to ensure stable environmental conditions. Some of the conducted research work is devoted to calendar aging during which the impact of ambient temperature and the current state of charge (SOC) is investigated. Examples of calendar aging models for LiFePO_4 , LiNiCoAlO_2 and LiNiCoMnO_2 cells can be found in [7].

In the case of the modeling of the state of health of LIBs during their cyclic operation, this issue is much more complex. The difficulty consists of the necessity to take into account many factors of cyclic operation which include, above all: ambient temperature (T_a), values of charging and discharging currents (I_{ch}/I_{dch}), depth of discharge (DOD) and current state of health (SOH_{act}). In specific situations, also the impact of high pressure and vibrations has been subject to investigation [8,9]. The aspect of analysis and modeling of the state of health (SOH) is affected by the fact that the impacts of the factors mentioned above are usually strongly non-linear [10] and the degradation patterns may differ depending on their current values. For this reason, it is possible to find simplified regression models in many papers [11]. These models usually take into account the impact of selected factors on the process of degradation of a cell [12,13]. For instance, in papers [14,15] a proposal was made that during the modeling of the state of health, it is necessary to take into account, above all, the ambient temperature and the average value of the load current. Paper [16] investigated the increase in internal resistance and the capacity fade of the LiFePO_4 cell, depending on the ambient temperature, average state of charge (SOC_{avg}), depth of discharge as well as charging and discharging currents. However, the developed model is applicable at temperatures of 25 °C and 40 °C and does not take into account the current state of health. Papers [17,18] investigated the impact of selected cyclic operation factors on the LIBs aging process and separate mathematical functions were developed for them. Paper [19] demonstrated the non-linear impact of the value of the charging current. The concept of SOH determination of batteries based on the damage accumulation model is also currently being developed and presented in the papers [20–22].

In recent years, SOH prediction models have also been developed. These models use various types of non-deterministic methods such as e.g. artificial neural networks (ANN) – feedforward [23] or recurrent [24], fuzzy logic systems and machine learning systems [11–13]. In comparison with regression models, there is no necessity in this approach to develop functions (often very complex), describing the LIBs degradation depending on cyclic operation factors. As a consequence of this, the possibility of analyzing the model's structure is limited and inability to predict SOH beyond the range of the training data. One example of a paper where an artificial neuron network was used to predict the effects of LIBs' degradation is [25]. In this paper, the non-destructive technique was used to investigate the aging effects, that is, the electrochemical impedance spectroscopy (EIS). On the other hand, in papers [26,27] the fuzzy logic systems were applied to determine the SOH and SOC of lithium-ion batteries and lead-acid batteries. An examples of data-driven approach used for on-line SOH estimation during driving patterns were presented in [28,29]. In [30] the sample entropy method was successfully used to analyze the capacity fade and identification the non-linearities between the parameters of cyclic operation of batteries. In paper [31] the use of a model based on improved autoregression by particle swarm optimisation was proposed to predict the capacity fade patterns of lithium-ion cell without taking into account the parameters of cyclic operation. In turn, in [32,33] a method of SOH prediction was developed using the support vector machine (SVM).

The Gaussian process regression technique described in this paper has been used before for the purpose of prediction of SOH

Table 1
Properties of the analyzed lithium-ion cell.

Model	18650 (cylindrical)
Manufacturer	Samsung
Nominal capacity	2.6 Ah
Nominal voltage	3.63 V
Anode material	Carbon
Cathode material	LiNi _{0.33} Mn _{0.33} Co _{0.33}
Voltage range	2.75 – 4.2 V

of lithium-ion cells only in short-term periods [34], or under variable environmental or load conditions [35]. This technique was also used during high-dimensional reliability analyzes [36].

The models developed so far have not taken into account the actual state of health of LIBs as consecutive duty cycles are performed. Analysis carried out by the authors of this paper demonstrated that this factor has a significant impact on the evolution of degradation trends, which has also been mentioned in [31,32]. With this in mind, the proposed model took into account the SOH_{act} which allowed, among other things, for the correct prediction of characteristic inflection points on SOH characteristics.

3. Experimental procedure

This chapter includes a description of the method implemented for conducting LIB aging tests (Section 3.1), presents the algorithm for the procedure during the reference capacity measurements (Section 3.2) and presents the methods used for data pre-processing and statistical analysis (Section 3.3). A general block diagram of experimental procedure is presented in Fig. 1.

3.1. Cycling procedure

Due to the fact that the degradation of LIBs depends on the values of the parameters of a full duty cycle, aging tests were conducted using commercial 18650 lithium-ion cells (LiNi_{0.33}Mn_{0.33}Co_{0.33}). Selected properties of the tested cell have been presented in Table 1.

During the aging tests, the cells were cycled inside the temperature chamber, which ensured a constant ambient temperature. The manufacturer of this cell recommends discharging current values that do not exceed 5.2 A (double one-hour current) as well as 1.3 A for standard charging and 2.6 A for fast charging, however, taking into account the time input needed to investigate many variants of operation – the authors decided, in some cases, to select values of cyclic operation which would exceed the values recommended by the manufacturer in order to force out their accelerated degradation. Regardless of the adopted values of discharging currents, the final discharging voltage was 2.75 V, while the final charging voltage in the constant voltage (CV) phase was 4.2 V (as per the manufacturer's guidelines). The CC–CV method was used as the method of charging the LIBs. The cyclic operation control during aging tests was ensured by battery testers dedicated to the electrochemical cells. Measurements of the electrical parameters of LIBs were performed on four wires (separate wires for the measurement of amperage and for the measurement of voltage on cell terminals). During the cycling of LIBs, their temperature was also measured using Pt100 probes located on the enclosure in the middle of their height. In order to obtain the degradation characteristics for LIBs under different loads and temperature conditions, the authors selected values of cyclic operation parameters (ambient temperature, charging and discharging current values and depth of discharge) over a wide range. During the aging tests, the ambient temperature ranged between 10 °C and 40 °C, the value of the average charging

current ranged between 1.61 A and 3.48 A, depth of discharge (DOD) was between 16% and 100%, values of discharging currents ranged between 2.6 A and 10.4 A, and the values of the actual SOH ranged between 100% and 80%.

The values of the cyclic operation parameters selected during the LIB testing have been listed in Table 2.

3.2. Capacity reference test

In order to determine the actual state of health (SOH_{act}), the cells were periodically subjected to capacity reference tests (CRTs), based on which their current capacity was determined. The interval between the consecutive CRTs was determined on the basis of observation of the rate of degradation of the cells and was 2 days. During the performance of the CRTs for all the LIBs under consideration, the following procedure was used:

1. Interruption of the currently implemented cyclic procedure after completing a discharging half-cycle.
2. Determination of the nominal cell temperature equal to 25 °C.
3. Charging of the cell to 4.2 V according to the constant current–constant voltage (CC–CV) procedure. The initial value of the charging current in the constant current phase was 1.3 A. The cell was charged until the value of the current in the constant voltage phase reached 5% of the initial value.
4. 15-second pause.
5. Discharging of the cell using the constant current (CC) method, to a voltage equal to 2.75 V - with a 2.6 A current.

Based on the capacity determined in this manner, the current state of health was determined according to the following relationship

$$SOH_{act} = \frac{C_{act}}{C_{BoL}} \cdot 100\% \quad (1)$$

where C_{BoL} is the capacity measured at the beginning of life (BoL) of the cell, and C_{act} is the current cell capacity.

Capacity is determined using Coulomb counting method which relies on the integration of the current drawn from the cell over time [37].

The condition for the termination of each aging test was the achievement of the end of life (EoL) criterion by the LIB, which was $SOH=80\%$.

On completion of the CRT procedure we propose to determine the cell aging ($dSOH/dNeq$) as the quotient between SOH obtained in the previous and actual CRT and the number of full equivalent cycles performed between the previous and actual CRT according to the following relationship

$$dSOH/dNeq = \frac{SOH_{pre} - SOH_{act}}{Neq_{pre} - Neq_{act}} \quad (2)$$

where SOH_{pre} is the state of health obtained in the previous CRT, SOH_{act} is the state of health obtained in the actual CRT, Neq_{pre} is the number of performed equivalent full cycles before the previous CRT, Neq_{act} is the number of performed equivalent full cycles before the actual CRT.

This approach makes it possible to take into account the capacity fade during the cyclic operation of the cell and to accurately determine the cell aging from BoL to EoL.

Due to the hysteresis phenomenon occurring during the cyclic operation of electrochemical batteries (for a given battery state of charge, the voltage at the terminals is higher during the charging half-cycle as compared to the discharge half-cycle and it is the higher current value [38]) when determining the number of full equivalent duty cycles, we decided to calculate the energy sepa-

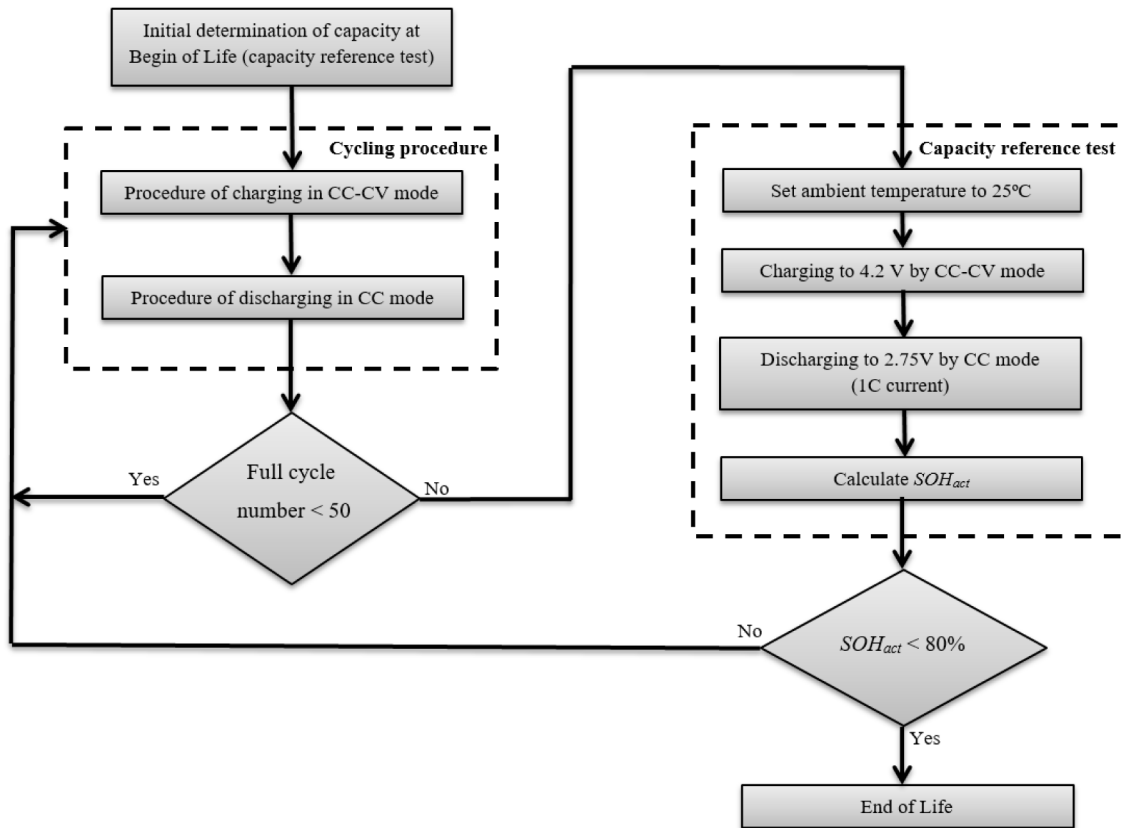


Fig. 1. A general block diagram of experimental procedure.

Table 2
Values of cycling parameters selected for aging procedures.

Variant number	Ambient temperature (°C)	Discharging current (A)	Depth of Discharge (%)	Average charging current (A)	Actual State of health (%)
1	10	2.6	73	2.4	
2	10	2.6	50	2.4	
3	10	2.6	27	1.8	
4	10	2.6	100	2.3	
5	10	7.8	100	2.6	
6	10	5.2	60	1.8	
7	10	2.6	67	1.7	
8	15	2.6	100	2.0	
9	15	5.2	100	2.3	
10	15	7.8	100	2.8	
11	15	5.2	50	2.2	
12	15	2.6	50	2.1	
13	15	5.2	100	1.8	
14	25	10.4	100	2.0	
15	25	7.8	100	2.8	
16	25	5.2	100	2.7	
17	25	2.6	100	2.0	
18	25	7.8	100	1.8	
19	25	5.2	100	2.0	
20	25	2.6	100	3.1	
21	25	5.2	50	2.2	
22	25	5.2	16	2.4	
23	40	7.8	100	2.8	
24	40	5.2	100	2.7	
25	40	2.6	100	2.4	
26	40	2.6	100	3.5	
27	25	2.6	100	3.3	
28	40	3.9	100	2.6	

for all tested LIBs the SOH range was 100–80

rately during the charge and discharge half-cycle according to the following equation

$$Neq = \frac{U_{dsch_avg} \cdot Q_{dsch} + U_{ch_avg} \cdot Q_{ch}}{U_{nom} \cdot Q_{tot}} \quad (3)$$

where U_{dsch_avg} is the average cell voltage during the discharging half-cycle, Q_{dsch} is the charge obtained during discharging, U_{ch_avg} is the average cell voltage during the charging half-cycle,

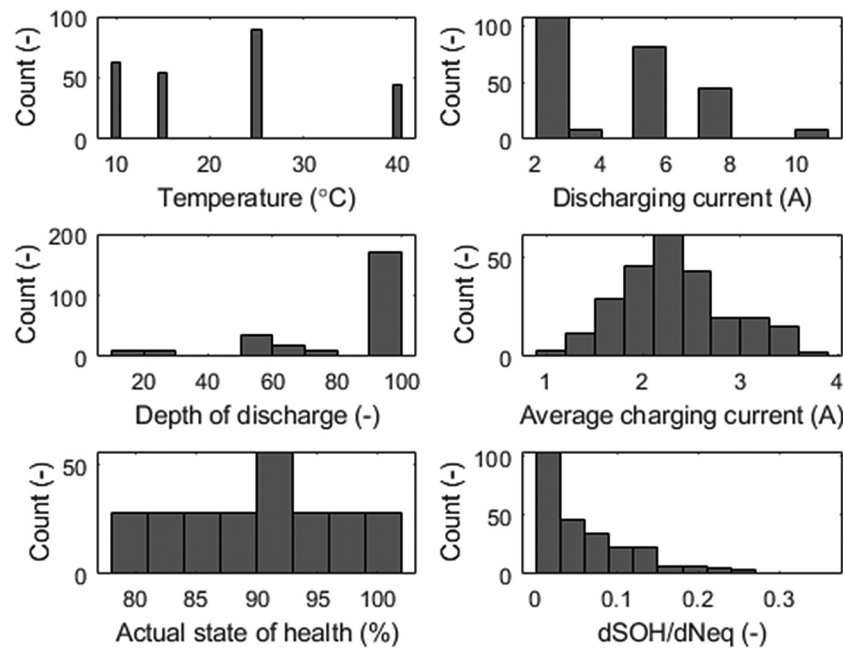


Fig. 2. Histogram of learning dataset.

Q_{ch} is the charge obtained during discharging, U_{nom} is the cell nominal voltage, Q_{tot} is the nominal charge during the full cycle.

In accordance with the above assumptions, one full equivalent duty cycle comprise transfer of energy equal to the rated energy during two consecutive half-cycles (charging and discharging).

3.3. Data pre-processing

Prediction models based on machine learning require appropriate data preparation. For this reason, a set of raw data was processed into the form of a learning dataset. Because of the fact that there were no missing values in the data, the authors did not use missing values handling techniques. All values in the dataset are of numerical type and were standardised (values have standard deviation of 1 and mean of 0). Fig. 2 presents histograms for the analyzed parameters of the cyclic operation of the LIBs.

Before proceeding with the statistical analysis, the zero hypothesis H_0 and alternative hypothesis H_1 were defined:

H_0 – “Parameters of cyclic operation have no impact on the aging of a LIB”

H_1 – “Parameters of cyclic operation have an impact on the aging of a LIB”

In order to determine the effects of the impacts of the respective factors of the full duty cycle of the LIB on $dSOH/dNeq$, the non-parametric test based on Spearman’s ranks was used (the authors made the assumption that this impact is non-linear, which has also been proven in other research papers [8,25,30]). For all samples of the learning dataset, the values of Spearman’s rank correlation coefficient ρ_s were calculated and the results were listed in Table 3.

The highest value ρ_s was obtained for the actual SOH, which gives the highest impact on $dSOH/dNeq$ from among all the analyzed factors. The impact of the actual SOH can be determined as moderately strong ($|\rho_s| > 0.6$). The second highest impact is exerted by the ambient temperature, and the discharging current and average charging current (both at similar levels). The impact of the ambient temperature can be determined as moderate ($0.6 > |\rho_s| > 0.3$). The lowest impact was demonstrated by the depth of discharge, charging current and discharging current ($|\rho_s| < 0.3$).

In order to verify the hypotheses mentioned above, the p -value which is related to the statistical significance of the test result was used. If the p -value obtained during the test is lower than the assumed level of significance α , then there are basics to reject the zero hypothesis and adopt the alternative hypothesis [10]. Otherwise there are no reasons to reject the zero hypothesis. $\alpha = 0.05$ was assumed as the significance level. The p -values for the conducted test have been presented in Table 3.

As has been shown in Table 3, for all the analyzed parameters of cyclic operation, the p -values have values lower than the adopted significance level, which allows for the rejection of the zero hypothesis and proves the validity of the alternative hypothesis – “Parameters of cyclic operation have an impact on the aging of a LIB”.

4. Proposed approach

The modeling of the state of health of LIBs may be divided into parts – calendar aging and cyclic duty aging. Due to the fact that it is possible to find many papers devoted to the modeling of calendar aging. For this reason in this paper, research was limited to the modeling the cyclic aging. As has been demonstrated in earlier research, the aging of LIBs depends on the factors of cyclic operation – ambient temperature, depth of discharge, charging and discharging currents values and the actual state of health. Bearing in mind that as the passive layer of a graphite electrode evolves, its resistance increases [39], causing faster reach of the constant voltage phase during the charging process and thus a shorter time of constant current phase – it is impossible to maintain a constant value of the charging current for the same time as the cell age. For this reason we adopt the average charging current in the model during the charging half-cycle. We have shown that in specific combinations of values of parameters of the full duty cycle, $dSOH/dNeq$ increases linearly in relation to the actual SOH. The effect was observed in 18 tested variants. In the remaining 10 variants, characteristic inflection points were observed. After these points were reached, accelerated or decelerated aging of the LIB took place. Examples of the obtained characteristics have been presented in Fig. 3.

Table 3
Values of Spearman's coefficients for all cycling parameters.

	Ambient temperature	Discharging current	Depth of Discharge	Average charging current	Actual State of Health
dSOH/dNeq	-0.4170	0.2398	-0.1363	-0.2800	-0.6240
p-value	<0.000001	0.000161	0.03371	0.000009	<0.000001




Fig. 3. Examples of aging patterns of the analyzed LIBs.

The marker (\blacktriangle) was used to mark the characteristic of the LIB (variants no. 1–7, 9–10, 12–13, 16–17, 19–22, 24 and 27 from Table 2), whose aging increases linearly as its actual SOH decreases. The characteristics which contain inflection points are shown as (\blacklozenge), in which a fast aging phase followed a slow degradation phase (variants no. 8, 14–15, 18, 23 and 25 from Table 2) and as (\blacksquare), in which the opposite effect was observed - a slow degradation phase followed a fast aging phase (variants no. 26 and 28 from Table 2). Identification of the causes of the occurrence of inflection points at specific combinations of values of factors of the full duty cycle is very complicated in view of the fact that it is impossible to separate the impact of these factors during the cycle and to test them separately. At the same time this is currently one of the greatest challenges when it comes to issues related to the prediction of $dSOH/dNeq$ LIBs. Fig. 4 shows a flowchart of the respective steps of the proposed method.

4.1. Cycle-life non-parametric model

In view of the fact that $dSOH/dNeq$ depends on the value of many cyclic operation factors, and moreover, this impact is often of non-linear nature, it is very difficult to develop a mathematical relationship which determines the impact of these factors on $dSOH/dNeq$. For this reason, the authors, for the purposes related to the prediction of $dSOH/dNeq$ in the function of factors of the full duty cycle (ambient temperature, discharging current, depth of discharge, average charging current and actual state of health) propose the use of the non-parametric model based on Gaussian process regression (GPR).

This technique is based on machine learning and may deliver good results in the case of small learning datasets as well. As opposed to parametric models, this approach does not require knowledge of the distribution of the analyzed factors and the analytic form between them. A great advantage of non-parametric models is the matching of the model form to the learning dataset. The accuracy of the prediction may also be easily increased by adding new learning data. Owing to this, it becomes possible to achieve more accurate forecasts than in the case of mathematical models. On the other hand, the interpretation of non-parametric models is limited or in certain cases almost impossible.

4.2. Gaussian process regression

GPR belongs to the group of probabilistic non-parametric kernel-based models [40,41]. For each finite set of input variables $x_i, i = 1, 2, \dots, n, n \in N^+$ it defines the probability distribution $p(f(x_i))$, which is jointly Gaussian (4). In other words GPR allows for the prediction of the response of model y' based on the given input vector x' and the learning dataset (y, x) .

$$f(x) \sim GP(m(x), cov(x, x')) \quad (4)$$

where $m(x)$ is the mean function, $cov(x, x')$ is the covariance function and x is the vector of input variables, $x \in R$.

In GPR, for each learning dataset x_i function $f(x_i)$ (called the latent variable which has the Gauss distribution) and function $h(x)$, which is the set of base functions that transfer the input vector x from the original feature space R^d to the extended feature space R^p were determined.

The mean and covariance functions used in GPR can be expressed as

$$m(x) = E(f(x)) \quad (5)$$

$$cov(x, x') = E((f(x) - m(x))(f(x') - m(x')))) = k(x, x') \quad (6)$$

where E is the expected value.

The covariance function $cov(x, x')$ is, in this approach, referred to as a kernel function. The kernel function receives two points (x, x') as input and returns a similarity between these points in the form of scalar $k(x, x')$. In other words, it determines how response y at point x is affected by responses at other points x' . It is possible to distinguish many different forms of kernel functions. The examples of standard kernel functions may include, e.g. rational quadratic (10), exponential (11), squared exponential (12), matern 5/2 (13) or matern 3/2 (14) - see Appendix A. The standard kernel functions contain parameters related to the scaling of the responses of model y and input vector x and are referred to as hyperparameters θ .

The following structure of the model was adopted for further considerations

$$y(x) = h(x)^T w + f(x) + \varepsilon \quad (7)$$

where $h(x)$ is the set of basis functions, w is the vector of basis function coefficients, ε is the noise which has normal distribution

$$\varepsilon \sim N(0, \sigma_n^2) \quad (8)$$

The relationships for determining the response using GPR model are included in Appendix B.

4.3. Results

The non-parametric regression method discussed in Section 4.2 was used to predict the aging of cyclically operating LIBs. The input variables of the model included: ambient temperature (T_a), value of discharging current (I_d), depth of discharge (DOD), value of average charging current during a half-cycle (I_{ch_avg}) and the actual state of health of the cell (SOH_{act}). The output variable of the model was the aging of the cell converted into the equivalent duty cycle ($dSOH/dNeq$). The learning dataset

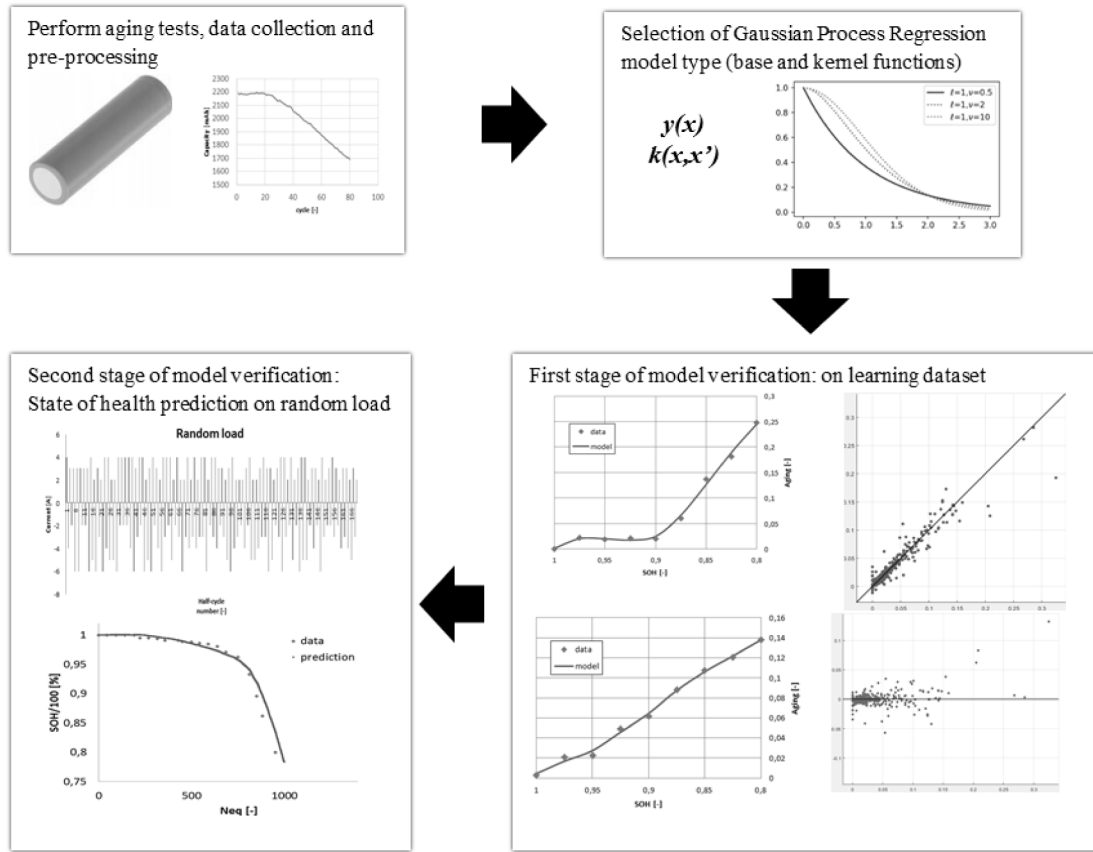


Fig. 4. Flowchart of the proposed method for SOH prediction.

Table 4
Data sample of learning dataset.

T_a (°C)	I_d (A)	DOD (%)	I_{ch_avg} (A)	SOH _{act} (%)	dSOH/dNeq (%)
25	5.2	50	2.08	92.5	0.02383

was constructed on the basis of measurement results and calculations presented in Sections 3.1 and 3.2 and contained 252 samples in total (learning dataset used in this paper is available online at: <http://dx.doi.org/10.17632/k6v83s2xdm.1>). An exemplary data sample of the learning vector \mathbf{X} has been presented in Table 4.

During the experiment, the impacts of selection of the type of base function $h(x)$ and the type of kernel function $k(x,x')$ on the quality of prediction were also analyzed. In order to evaluate the model, the following indicators were used: mean absolute percentage error (MAPE) and root mean square error (RMSE)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y_{ip}}{y_i} \right| \cdot 100\% \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_{ip})^2} \quad (10)$$

where y_i is the measured value, y_{ip} is the predicted value, n is the number of data samples.

The best obtained results for the learning dataset, the maximum value of the marginal log likelihood function L and optimal values of hyperparameters for each kernel function have been listed in Table 5, while the detailed characteristics of aging for

each LIB learning dataset have been presented in Fig. 5. To determine the optimal values of hyperparameters (σ_l , σ_f and α) the unconstrained optimisation method (quasi-Newton) was used.

4.4. Verification

The second part of verification of the model consisted of subjecting the cells to a randomly variable load. First cell (test A) was cycled at an ambient temperature of 10 °C and at a constant DOD equal to 16% ($Neq = 0.32$), and second (test B) was cycled at ambient temperature equal to 15 °C at a constant DOD equal to 48% ($Neq = 0.96$). Values of charging currents were drawn from the range from 2 A to 4 A and discharging currents from -2 A to -6 A. The number of draws of the respective values of currents for the duty cycle for both cell was listed in Table 6.

A drawn sequence of duty cycles was introduced into model 5, and then a simulation of the degradation of the LIB during cyclic operation from SOH = 100% to SOH = 80% was performed (the only breaks were related to the CRT performance). APE was used to evaluate the prediction. The obtained results have been presented in Fig. 6.

5. Discussion

The use of the non-parametric SOH prediction model of LIBs made it possible to map the trends in their aging depending on the values of the parameters of cyclic operation. The developed method is an improvement to the existing methods for SOH prediction. However, it requires knowledge of the actual SOH of the LIB. The impacts of the base function $h(x)$ and the kernel function $k(x,x')$ were considered in the paper in different configurations. In each variant, the trained model was a learning dataset

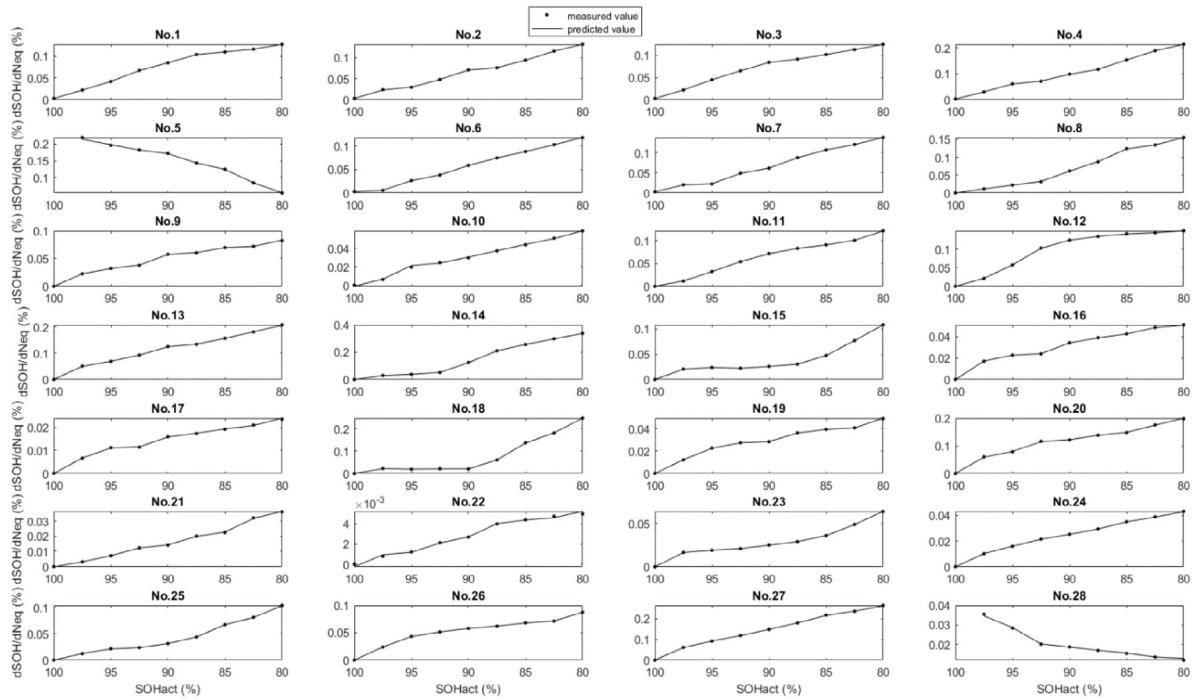


Fig. 5. Results of verification of the learning dataset (model 5).

Table 5
Results of evaluation on learning dataset.

	Kernel	$h(x)$	MAPE (%)	$R^2(-)$	$L (-)$	RMSE (-)	$\sigma_f (-)$	$\sigma_l (-)$	$\alpha (-)$
model 1	RQ	constant	6.03	0.96	661.4	0.0116	0.1812	3.806	0.1029
model 2	M5	constant	5.15	0.96	659.6	0.0117	0.0584	1.7764	-
model 3	Exp	constant	0.07	0.94	589.7	0.0149	0.1956	113.53	-
model 4	SE	linear	7.37	0.96	670.4	0.0117	0.0477	1.1251	-
model 5	M3	linear	2.27	0.96	661.1	0.0119	0.0984	2.42	-

Table 6
Currents drawn for second stage of verification.

Current (A)	Number drawn (test A)	Number drawn (test B)
-2	1354	202
-3	1514	227
-4	1643	192
-5	1620	236
-6	1491	190
2	2408	344
3	2722	351
4	2513	356

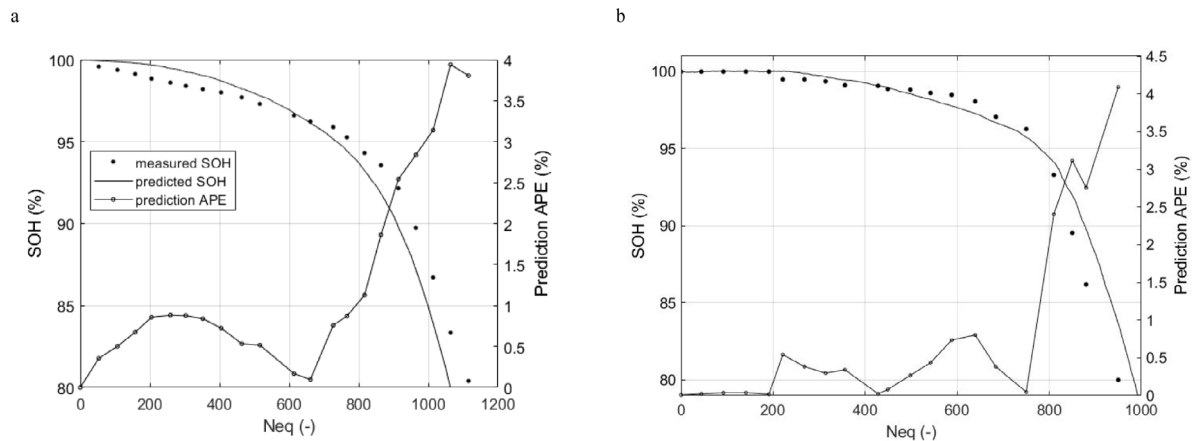


Fig. 6. Results of second stage verification – cycling LIBs by random load currents: (a) test A, (b) test B.

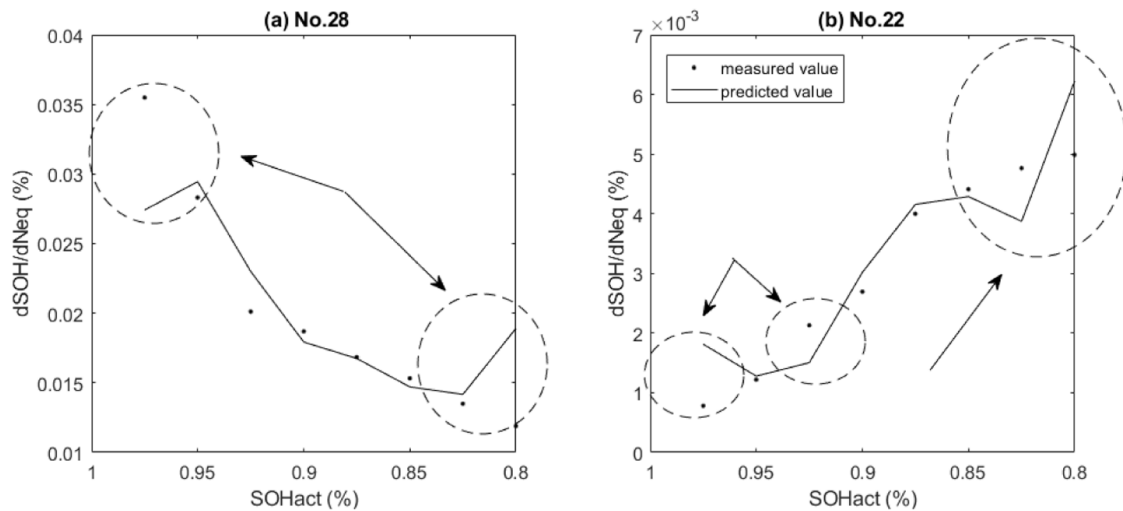


Fig. 7. Areas of wrong predictions at: (a) model 1, (b) model 2.

including 252 samples obtained on the basis of measurements of the degradation of 28 LIBs (Table 2).

The first three models contained constant base functions at kernel functions: rational quadratic (model 1), matern 5/2 (model 2) and exponential (model 3) respectively. In the case of model 1, MAPE exceeded 6%, which was caused, above all, by the mistaken prediction of the degradation of the cell from variant no. 28 at high (above 95%) and low (below 83%) SOH_{act} – these areas are marked by an ellipsis in Fig. 7(a).

This problem also appeared in model 2 – MAPE = 5.15%. Model 3 is characterised by the smallest (MAPE = 0.07%) error among all the analyzed models. The application of the exponential kernel function resulted in the prediction characteristics going perfectly through the learning points. Because of the overfitting, the models with exponential kernel functions were not taken into account in further analyses.

Models 4 and 5 contained linear base functions at kernel functions, i.e. squared exponential (model 4) and matern 3/2 (model 5) accordingly. Model 4 is characterised by the biggest error (MAPE = 7.37%) among all the analyzed models. In this case, predictions with the largest errors referred to cells no. 28 and no. 22 – Fig. 7(b). Model 5 (MAPE = 2.27%) was selected for the second stage of verification, whereby its prediction values matched the general cell degradation patterns in the best way (degradation characteristics are in close proximity with the learning points), and this is presented in Fig. 5.

Because of the fact that LIBs are used more and more commonly to power objects characterised by variable load consumption in time (e.g. electrical vehicles), and to work together with sources which use renewable energy (RE) [42], the second stage of verification was aimed at the simulation of their degradation under random load conditions. During the whole period of simulation, the absolute prediction error (APE) in both cases did not exceed 5% which is a satisfactory result in the opinion of the authors. Furthermore, the model correctly determined the inflection point after which the fast aging phase was observed (which for both verified cases occurred at approximately $Neq = 800$), which confirms its practical usefulness.

The methodology presented in the paper can be used to develop SOH prediction models for electrochemical batteries operating cyclically of other types. These models can be successfully implemented in battery management systems and thus extend their current functionality (mainly related to protection against overcharging, overdischarging and overheating).

The greatest advantage of the proposed method compared to other knowledge-based models (for example artificial neural networks or fuzzy logic models) is the possibility of extrapolation.

6. Conclusion

The considerations presented in the article refer to the issue of the prediction of the state of health of LIBs at specific cyclic operation parameters. The modeling of the state of health of LIBs is a complex issue because of the necessity to take into account many parameters of the full duty cycle (thermal and electrical ones). For this reason, with some many input parameters, models based on machine learning are best suited for the prediction of the state of health of LIBs. Bearing in mind the current state of knowledge of the authors, the prediction model of the SOH developed in this paper is the first model which takes into account the previous history of the LIB aging and the impacts of actual values of cyclic operation factors. The conducted test demonstrated that the model also enables the correct detection of characteristic inflection points, after which, the fast aging phase takes place, which is currently the subject of many research papers.

The method proposed by the authors is a new solution, which allows for the prediction of the state of health of LIBs at different load patterns, with a relatively small learning dataset. During the verification of the model under conditions of randomly variable load, the obtained prediction error during the entire lifespan of the both LIBs did not exceed 5%. One of the most important aspects of the GPR method is the proper selection of the base function and kernel function. As the conducted tests demonstrated – the improper selection of these functions may lead to the poor generalisation of knowledge and the occurrence of the overfitting phenomenon.

CRedit authorship contribution statement

Damian Burzyński: Conceptualization, Methodology, Software, Data curation, Writing - original draft, Visualization, Investigation, Validation, Resources, Formal analysis, Writing - review & editing, Project administration. **Leszek Kasprzyk:** Methodology, Writing - original draft, Supervision, Resources, Formal analysis.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Appendix A

Kernel functions used in the analysis:

1. Rational quadratic

$$k_{RQ}(x, x') = \sigma_f^2 \left(1 + \frac{r^2}{2\alpha\sigma_l^2} \right)^{-\alpha} \quad (11)$$

2. Exponential

$$k_{EXP}(x, x') = \sigma_f^2 \exp\left(-\frac{r}{\sigma_l}\right) \quad (12)$$

3. Squared exponential

$$k_{SQEXP}(x, x') = \sigma_f^2 \exp\left(-\frac{1}{2} \frac{(x-x')^T(x-x')}{\sigma_l^2}\right) \quad (13)$$

4. Mattern 5/2

$$k_{MAT5}(x, x') = \sigma_f^2 \left(1 + \frac{\sqrt{5}r}{\sigma_l} + \frac{5r^2}{3\sigma_l^2} \right) \exp\left(-\frac{\sqrt{5}r}{\sigma_l}\right) \quad (14)$$

5. Mattern 3/2

$$k_{MAT3}(x, x') = \sigma_f^2 \left(1 + \frac{\sqrt{3}r}{\sigma_l} \right) \exp\left(-\frac{\sqrt{3}r}{\sigma_l}\right) \quad (15)$$

where r is the Euclidean distance between x and x' , σ_l is the characteristic length scale, σ_f is the standard deviation, α is the scale parameter ($\alpha > 0$).

Appendix B

The GPR model response can be determined by following relationship:

$$P(\mathbf{y}|\mathbf{f}, \mathbf{X}) \sim N(\mathbf{y}|\mathbf{H}\mathbf{w} + \mathbf{f}, \sigma^2\mathbf{I}_n) \quad (16)$$

where \mathbf{I}_n is the identity matrix, n is the number of training data samples.

$$\mathbf{y} = (y_1 \quad y_2 \quad \dots \quad y_n)^T \quad (17)$$

$$\mathbf{f} = (f(x_1) \quad f(x_2) \quad \dots \quad f(x_n))^T \quad (18)$$

$$\mathbf{X} = (x_1^T \quad x_2^T \quad \dots \quad x_n^T)^T \quad (19)$$

$$\mathbf{H} = (h(x_1^T) \quad h(x_2^T) \quad \dots \quad h(x_n^T))^T \quad (20)$$

The joint probability distribution of latent variables in the GPR model, with the assumption of the zero average function $m(x) = 0$ is described by

$$P(\mathbf{f}|\mathbf{X}) \sim N(\mathbf{f}|\mathbf{0}, \mathbf{K}(\mathbf{X}, \mathbf{X}')) \quad (21)$$

where

$$\mathbf{K}(\mathbf{X}, \mathbf{X}') = \begin{pmatrix} k(x_1, x'_1) & k(x_1, x'_2) & \dots & k(x_1, x'_n) \\ k(x_2, x'_1) & k(x_2, x'_2) & \dots & k(x_2, x'_n) \\ \dots & \dots & \dots & \dots \\ k(x_n, x'_1) & k(x_n, x'_2) & \dots & k(x_n, x'_n) \end{pmatrix} \quad (22)$$

The values of the hyperparameters of the kernel functions were determined by maximising the marginal log likelihood function $P(\mathbf{y}|\mathbf{X})$ in relation to parameters w, θ, σ^2

$$\begin{aligned} & \log P(\mathbf{y}|\mathbf{X}, w, \theta, \sigma^2) \\ &= -\frac{1}{2} (\mathbf{y} - \mathbf{H}\mathbf{w})^T [\mathbf{K}(\mathbf{X}, \mathbf{X}') + \sigma^2\mathbf{I}_n]^{-1} \\ & \quad \times (\mathbf{y} - \mathbf{H}\mathbf{w}) - \frac{n}{2} \log 2\pi - \frac{1}{2} \log |\mathbf{K}(\mathbf{X}, \mathbf{X}') + \sigma^2\mathbf{I}_n| \end{aligned} \quad (23)$$

With the known parameters of the GPR model, the probabilistic prediction of value y_{new} for new values of the input vector \mathbf{x}_{new} requires the determination of $P(y_{new}|\mathbf{y}, \mathbf{X}, \mathbf{x}_{new})$

$$P(y_{new}|\mathbf{y}, \mathbf{X}, \mathbf{x}_{new}) = \frac{P(y_{new}, \mathbf{y}|\mathbf{X}, \mathbf{x}_{new})}{P(\mathbf{y}|\mathbf{X}, \mathbf{x}_{new})} \quad (24)$$

References

- [1] Global E. V. Outlook, Glob. EV outlook 2020, 2020, (Available: <http://www.iea.org>, Access: 05 January 2021).
- [2] United States Advanced Battery Consortium, USABC Goals for Advanced Batteries for Evs - CY 2020 Commercialization(available: http://www.uscar.org/comm{and}s/files_download.php?files_download.php?files_id=364).
- [3] R. Xiong, J. Cao, Q. Yu, H. He, F. Sun, Critical review on the battery state of charge estimation methods for electric vehicles, IEEE Access 6 (2017) 1832–1843.
- [4] J. Vetter, et al., Ageing mechanisms in lithium-ion batteries, J. Power Sources 147 (1–2) (2005) 269–281.
- [5] V.A. Sethuraman, L.J. Hardwick, V. Srinivasan, R. Kostecki, Surface structural disordering in graphite upon lithium intercalation/deintercalation, J. Power Sources 195 (11) (2010) 3655–3660.
- [6] D.I. Stroe, M. Swierczynski, S.K. Kær, R. Teodorescu, Degradation behavior of lithium-ion batteries during calendar ageing - the case of the internal resistance increase, IEEE Trans. Ind. Appl. 54 (1) (2018) 517–525.
- [7] P. Keil, et al., Calendar aging of lithium-ion batteries, J. Electrochem. Soc. 163 (9) (2016) A1872–A1880.
- [8] T.C. Bach, et al., Nonlinear aging of cylindrical lithium-ion cells linked to heterogeneous compression, J. Energy Storage 5 (2016) 212–223.
- [9] L. De Sutter, et al., Comprehensive aging analysis of volumetric constrained lithium-ion pouch cells with high concentration silicon-alloy anodes, Energies 11 (11) (2018).
- [10] T. Gewald, A. Candusso, L. Wildfeuer, D. Lehmkuhl, A. Hahn, M. Lienkamp, Accelerated aging characterization of lithium-ion cells: Using sensitivity analysis to identify the stress factors relevant to cyclic aging, Batteries 6 (1) (2020) 1–18.
- [11] M.-F. Ng, J. Zhao, Q. Yan, G.J. Conduit, Z.W. Seh, Predicting the state of charge and health of batteries using data-driven machine learning, Nat. Mach. Intell. 2 (3) (2020) 161–170.
- [12] G. Suri, S. Onori, A control-oriented cycle-life model for hybrid electric vehicle lithium-ion batteries, Energy 96 (2016) 644–653.
- [13] M. Bercibar, I. Gandiaga, I. Villarreal, N. Omar, J. Van Mierlo, P. Van Den Bossche, Critical review of state of health estimation methods of li-ion batteries for real applications, Renew. Sustain. Energy Rev. 56 (2016) 572–587.
- [14] T. Liu, L. Cheng, Z. Pan, Q. Sun, Cycle life prediction of lithium-ion cells under complex temperature profiles, Ekspolatacja i Niezawodn. - Maint. Reliab. 18 (1) (2016) 25–31.
- [15] X. Han, M. Ouyang, L. Lu, J. Li, Cycle life of commercial lithium-ion batteries with lithium titanium oxide anodes in electric vehicles, Energies 7 (8) (2014) 4895–4909.
- [16] M. Naumann, F. Spingler, A. Jossen, Analysis and modeling of cycle aging of a commercial LiFePO4/graphite cell, J. Power Sources 451 (2019) 227666, 2020.
- [17] D. Burzyński, R. Pietracho, L. Kasprzyk, A. Tomczewski, Analysis and modeling of the wear-out process of a lithium-nickel-manganese-cobalt cell during cycling operation under constant load conditions, Energies 12 (20) (2019) 3899.
- [18] N. Omar, et al., Lithium iron phosphate based battery - assessment of the aging parameters and development of cycle life model, Appl. Energy 113 (2014) 1575–1585.
- [19] Y. Gao, J. Jiang, C. Zhang, W. Zhang, Z. Ma, Y. Jiang, Lithium-ion battery aging mechanisms and life model under different charging stresses, J. Power Sources 356 (2017) 103–114.
- [20] Domen Šeruga, Aleš Gosar, Caoimhe A. Sweeney, Joris Jaguemont, Joeri Van Mierlo, Marko Nagode, Continuous modelling of cyclic ageing for lithium-ion batteries, Energy B 215 (2021).
- [21] C. Dudézet, Y. Reynier, J.M. Duffault, S. Franger, Fatigue damage approach applied to li-ion batteries ageing characterization, Mater. Sci. Eng. B Solid-State Mater. Adv. Technol. 213 (2016) 177–189.
- [22] M. Safari, M. Morcrette, A. Teyssot, C. Delacourt, Life prediction methods for lithium-ion batteries derived from a fatigue approach, J. Electrochem. Soc. 157 (7) (2010) A892.
- [23] J. Wu, C. Zhang, Z. Chen, An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks, Appl. Energy 173 (2016) 134–140.
- [24] H. Chaoui, C.C. Ibe-Ekeocha, State of charge and state of health estimation for lithium batteries using recurrent neural networks, IEEE Trans. Veh. Technol. 66 (10) (2017) 8773–8783.

- [25] A. Eddahech, O. Briat, N. Bertrand, J.Y. Deléage, J.M. Vinassa, Behavior and state-of-health monitoring of li-ion batteries using impedance spectroscopy and recurrent neural networks, *Int. J. Electr. Power Energy Syst.* 42 (1) (2012) 487–494.
- [26] A. Zenati, P. Desprez, H. Razik, Estimation of the SOC and the SOH of Li-ion batteries, by combining impedance measurements with the fuzzy logic inference, in: *IECON Proc. (Industrial Electron. Conf., 2010*, pp. 1773–1778.
- [27] D. Reisner, Fuzzy Logic-Based State-of-Health Determination, pp. 583–590.
- [28] G. won You, S. Park, D. Oh, Real-time state-of-health estimation for electric vehicle batteries: A data-driven approach, *Appl. Energy* 176 (2016) 92–103.
- [29] K.A. Severson, P.M. Attia, N. Jin, et al., Data-driven prediction of battery cycle life before capacity degradation, *Nat. Energy* 4 (2019) 383–391.
- [30] X. Hu, J. Jiang, D. Cao, B. Egardt, Battery health prognosis for electric vehicles using sample entropy and sparse Bayesian predictive modeling, *IEEE Trans. Ind. Electron.* 63 (4) (2016) 2645–2656.
- [31] B. Long, W. Xian, L. Jiang, Z. Liu, An improved autoregressive model by particle swarm optimization for prognostics of lithium-ion batteries, *Microelectron. Reliab.* 53 (6) (2013) 821–831.
- [32] A. Nuhic, T. Terzimehic, T. Soczka-Guth, M. Buchholz, K. Dietmayer, Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods, *J. Power Sources* 239 (2013) 680–688.
- [33] V. Klass, M. Behm, G. Lindbergh, A support vector machine-based state-of-health estimation method for lithium-ion batteries under electric vehicle operation, *J. Power Sources* 270 (2014) 262–272.
- [34] R.R. Richardson, M.A. Osborne, D.A. Howey, Gaussian Process regression for forecasting battery state of health, *J. Power Sources* 357 (2017) 209–219.
- [35] R.R. Richardson, M.A. Osborne, D.A. Howey, Battery health prediction under generalized conditions using a Gaussian process transition model, *J. Energy Storage* 23 (March) (2019) 320–328.
- [36] T. Zhou, Y. Peng, Kernel principal component analysis-based Gaussian process regression modelling for high-dimensional reliability analysis, *Comput. Struct.* 241 (2020) 106358.
- [37] A.G. Stefanopoulou, Y. Kim, 10 - system-level management of rechargeable lithium-ion batteries, in: *Rechargeable Lithium Batteries*, Woodhead Publishing, 2015, pp. 281–302.
- [38] V.J. Ovejas, A. Cuadras, Effects of cycling on lithium-ion battery hysteresis and overvoltage, *Sci. Rep.* 9 (1) (2019) 1–9.
- [39] C.R. Birkl, M.R. Roberts, E. McTurk, P.G. Bruce, D.A. Howey, Degradation diagnostics for lithium ion cells, *J. Power Sources* 341 (2017) 373–386.
- [40] C.E. Rasmussen, Ch.K. Williams, *Gaussian Processes for Machine Learning*, MIT press Cambridge, 2006, p. 1.
- [41] E. Schulz, M. Speekenbrink, A. Krause, A tutorial on Gaussian process regression: Modelling, exploring, and exploiting functions, *J. Math. Psych.* 85 (2018) 1–16.
- [42] A. Dobrzycki, D. Kurz, S. Mikulski, G. Wodnicki, Analysis of the impact of building integrated photovoltaics (BIPV) on reducing the demand for electricity and heat in buildings located in Poland, *Energies* 13 (10) (2020).

Article

Analysis and Modeling of the Wear-Out Process of a Lithium-Nickel-Manganese-Cobalt Cell during Cycling Operation under Constant Load Conditions

Damian Burzyński *, Robert Pietracho , Leszek Kasprzyk and Andrzej Tomczewski

Institute of Electrical Engineering and Electronics, Poznan University of Technology, Piotrowo 3A, 60-965 Poznan, Poland; robert.pietracho@put.poznan.pl (R.P.); leszek.kasprzyk@put.poznan.pl (L.K.); andrzej.tomczewski@put.poznan.pl (A.T.)

* Correspondence: damian.burzynski@put.poznan.pl

Received: 14 September 2019; Accepted: 14 October 2019; Published: 15 October 2019



Abstract: This article describes the analyses of modeling the wear process of lithium-nickel-manganese-cobalt cells operating cyclically under constant load conditions. The main aging processes taking place in cells and the methodology of the modeling are discussed. The process of cell wear is examined, taking into account the influence of cyclic operating parameters (temperature, discharge current, and discharge depth). On the basis of the analyses carried out, a new function reflecting the influence of ambient temperature on the durability of the cell is proposed. A new fuzzy model of the wear process of the NMC 18650 type cell, depending on the parameters of the discharge half cycle, has been developed. The results of the model have been verified by experimental research.

Keywords: lithium-ion cell life; battery modeling; cycle life modeling; fuzzy modeling

1. Introduction

The first electrochemical cells were designed, built and described more than 200 years ago, but it was only in the last three decades that the emergence of lithium-ion cells contributed to the dynamic growth of their popularity. The areas of their application are constantly expanding, and the most common are currently mobile electronic devices, various types of e-mobility solutions (especially electric vehicles), uninterruptible power supply systems, and systems cooperating with renewable sources of electricity [1]. Where the cost of cell purchase is significant and the load is characterized by high dynamics of change, the analysis of cell behaviour, both in electrical and thermal aspects, is very important [2,3]. For this purpose, various types of cell models are being developed all over the world, the most popular of which are electrochemical [4,5] and circular [6–8] models. At their core, all kinds of battery management systems are functioning, which allows the prediction of currents and voltages at cell terminals and the state of charge, while they control the charging process in a way that ensures safety. Without such systems, the cells could wear out excessively.

Another very important aspect of cell modeling is determining the state of health (*SOH*) of cells, both for economic and ecological reasons. Up-to-date research on this issue is important, because knowledge of the cell wear process can be used to design systems powered by electrochemical energy storage to optimize their operation, extend the time of proper battery operation, and thus reduce the consumption of rare earth elements. For this reason, many papers on modeling the process of lithium-ion battery consumption are found in the literature [9–12].

In this work, we focused on the issue of modeling the *SOH* of lithium-ion NMC cells. Due to the fact that for most types of cells, ageing models during storage are already developed [13,14], this paper deals with the issue of modeling the process of lithium-ion cell wear resulting from cyclic operation.

The analysis of cell wear resulting from cyclic operation should take into account many factors that have a significant impact on its *SOH*, related to temperature, electric field strength and current density in the electrolyte, double layers, and electrodes [15]. The issue is also hampered by the fact that the nature of this impact is strongly nonlinear. Therefore, in some works, numerous simplifications of the models were made, for example, [16] reported that during *SOH* modeling it is mainly the amount of electric charge exchanged by the cell that must be taken into account. In [17,18], models of cell *SOH* were proposed for cells operating at a constant temperature or under a constant load. Many sources suggest taking into account different operating parameters, but assume only their averaged values during the cycle. In [9], it was assumed that the effect of temperature on *SOH* is a polynomial of the third order, whereas discharge currents, charging currents, and depth of discharge (*DOD*) are exponential or power [11,19]. For the average state of charge (SOC_{avg}), linear or polynomial functions of the second order are assumed [16,20]. In [20], it was indicated that when the cell is operating with a dynamically changing load, the *DOD* changes should be considered separately for the charging and discharging processes. In [21], the nonlinear influence of the value of the charging current was also proved. The aforementioned works either lack consideration of important parameters of cell cyclic operation or address them too narrowly. It is against this background that we undertook to develop a model of cell wear process depending on ambient temperature, the value of discharge current, and the depth of discharge.

Taking all these parameters into account makes the identification of model coefficients difficult and time-consuming. A certain solution to the problem of creating complex mathematical functions, enabling the analysis of cell ageing, and determining the coefficients of these functions is the use of fuzzy logic. For this reason, we proposed the use of a fuzzy Mamdani system to analyze the state of consumption, which is a new approach to issues related to the modeling of the consumption of lithium-ion cells.

2. Aging Processes in Lithium-Ion Cells

Aging processes take place throughout the life cycle of lithium-ion cells, both in cyclic operation mode and in the storage state. These processes take place in the whole of the cell area, i.e., on the electrodes, in the electrolyte, and in the contact area between the phases of the electrodes and the electrolyte. According to many research papers, at least a dozen aging processes may be indicated, and their causes may have different physical characters (e.g., thermal, chemical, and electrochemical) [22,23]. Table 1 presents the dominating aging processes occurring in lithium-ion cells as a result of electrochemical processes.

Table 1. Main aging processes taking place in lithium-ion cells (Adapted from [24]).

No.	Name of Process
1	Formation, build-up, fracture and reformation of the solid electrolyte interphase (SEI)
2	Corrosion of the current collector
3	Decomposition and fracture reaction of the electrolyte and binder
4	Viscoelastic creep of the separator
5	Lithium plating
6	Gassing of the particles

The processes listed in Table 1 occur as a result of the electric charge flow during cyclic cell operation (charging and discharging processes). The speed of these processes is affected by the following cyclic operating parameters: cell temperature (T), charging current (I_{ch}), discharge current (I_d), discharge depth, and average state of charge of the cell. The aging processes responsible for the formation and subsequent evolution of the SEI layer are caused, among other things, by the use of the cell in the wrong voltage range (the high value of the final charging voltage is particularly unfavourable), the cell temperature, and the high current values during charging and discharging.

Corrosion of the current collector is caused by deep discharge of the cell (below the final discharge voltage), overcharging of the cell (above the final charging voltage), and storing the cell in an elevated ambient temperature. Conversely, the process of lithium plating of the cell is mainly caused by cyclic work in low temperatures. This process can be intensified if the charging current is high in these conditions. In the decomposition and fracture reactions of the electrolyte and binder, high temperatures and pressures in the cell, operating with a high state of charge of the cell (SOC), and overcharging of the cell can be triggers. Gassing occurs especially in the final phase of cell charging. The higher the temperature of the cell and the higher the charging current, the more intensively this process occurs. Aging processes can also be caused by various types of mechanical damage to the cell structure, for example, vibration or high pressure [25]. They can lead to viscoelastic creep of the separator. The use of mechanically damaged cells is particularly dangerous. In addition to the unstable operation of the cell in these situations, there is also a high risk of fire. Without interfering with the structure of the cell, the effects of these processes can only be analyzed by parameters such as internal resistance (growth) and capacity (atrophy).

3. Modeling the Wear Process of Lithium-Ion Cells

The following parameters can be taken as measures of the wear of cells (SOH, state of health):

- loss of cell capacity (as a result of gradual loss of capacity to accumulate electric charge);
- increase of internal resistance [26] (in some applications it is assumed that the cell is worn out when internal resistance doubles in relation to the resistance of the new cell);
- number of complete charge and discharge cycles (N) the cell can complete before cell capacity loss reaches 20% (criterion used for electric vehicles according to ISO 124052);
- exploitation time (applies to aging resulting from storage time).

Modeling of the wear process of lithium-ion cells is divided into two stages, during storage and during cyclic operation. In the first case, the charging state and ambient temperature are factors that have a particular impact on the wear of the cells. In the case of cyclic operation, the factors to be taken into account in the model are cell temperature, and discharge and charging currents (*DOD*).

In order to model the process of cell wear, the current international literature often uses mathematical multiplication models expressed in general form by means of the following equation [11,19,20,27]:

$$SOH(T, I_d, I_{ch}, DOD) = f(T) \cdot f(I_d) \cdot f(I_{ch}) \cdot f(DOD) \quad (1)$$

where *SOH* is the state of health of the cell, $f(T)$ is the function describing the impact of temperature, $f(I_d)$ is the function describing the impact of discharging current, $f(I_{ch})$ is the function describing the impact of charging current, and $f(DOD)$ is the function describing the impact of depth of discharge.

A model which allows for the estimation of the number of performed full equivalent cycles and useful capacity as the function of the depth of discharge, temperature, and load was developed in [9]. In this model, the impact of cycling on the useful capacity of the cell is described by the following equation [9]:

$$Q(n) = Q_{BOL} - \varepsilon(n) \cdot (Q_{BOL} - Q_{EOL}) \quad (2)$$

where n is the cycle number, Q_{BOL} is the capacity at beginning of life (new cell) (Ah), ε is the aging factor (-), and Q_{EOL} is the capacity at end of cell life (Ah).

The cell aging factor $\varepsilon(n)$ is determined according to the following formula [9]:

$$\varepsilon(n) = \varepsilon(n-1) + \frac{0.5}{N(n-1)} \left(2 - \frac{DOD(n-2) + DOD(n)}{DOD(n-1)} \right) \quad (3)$$

where N is the maximum number of cycles (-).

The maximum number of cycles can be calculated from the following relationship [9]:

$$N(n) = H \left(\frac{DOD(n)}{100} \right)^{-\xi} \exp \left(-\psi \left(\frac{1}{T_{ref}} - \frac{1}{T_a(n)} \right) \right) \cdot (I_{d_avg}(n))^{-\gamma_1} (I_{ch_avg}(n))^{-\gamma_2} \quad (4)$$

where H is the cycle number constant (-), ξ is the constant related to DOD (-), ψ is the Arrhenius rate for cycle number (-), I_{d_avg} is the average discharge current in half-cycle duration (A), I_{ch_avg} is the average charge current in half-cycle duration (A), γ_1 is the constant related to discharge current (-), γ_2 is the constant related to charge current (-), T_{ref} is the nominal temperature ($^{\circ}\text{C}$), and T_a is the ambient temperature ($^{\circ}\text{C}$).

The above model assumes that the DOD for the discharge process is the same as for the charging process. Cui et al. [19] developed a model of capacity atrophy for LiCoO₂ cells depending on temperature (T), discharge current (C), DOD, upper cut-off voltage (V_t), and number of cycles. This model is only suitable for shallow discharges and low load currents. Capacity loss is determined on the basis of equations [19]:

$$Q_{loss}(T, C, DOD, V_t, n) = A(DOD, C, V_t) \cdot \exp \left(-\frac{E_a(C)}{8.314 \cdot T} \right) \cdot n^{0.74} \quad (5)$$

$$A(DOD, C, V_t) = -157.671 + 3.624 \cdot DOD + 14.19 \cdot C + 2.721 \cdot \exp(0.938 \cdot V_t) \quad (6)$$

where E_a is the activation energy (J), n is the number of cycles (-), A is the pre-exponential factor (-). Where the cell is dynamically loaded with a variable load, DOD changes should be considered separately for the charging and discharging processes. Then, the analytical formula can be very complex, as in [20], in which the number of cycles that a lithium-ion cell can perform is determined by the relation:

$$N(I_{CH}, I_D, \Delta DOD, SOC, T) = N_0 \left[2 : \left(\frac{1}{a_{CH} \exp \left(\frac{-b_{CH} I_{CH}}{C_n} \right)} + \frac{1}{a_D \exp \left(\frac{-b_D I_D}{C_n} \right)} \right) \right] \cdot \frac{a_{\Delta DOD}}{\Delta DOD_D^{b_{\Delta DOD}} + \Delta DOD_{CH}^{b_{\Delta DOD}}} \cdot (c_{SOC} SOC_{avg}^2 + b_{SOC} SOC_{avg} + a_{SOC}) \cdot (d_T T^3 + c_T T^2 + b_T T + a_T) \quad (7)$$

where N_0 is the constant depending on the analyzed cell, adjusting the obtained result to the number of cycles at rated conditions; ΔDOD_{CH} is the change in the discharge depth (relative amount of electric charge delivered) during charging; ΔDOD_D is the change in the discharge depth (relative amount of electric charge taken out) during discharge; a, b, c, d are the coefficients depending on the analyzed cell, with indexes related to cyclic model parameters; and C_n is the rated capacity of the cell.

4. Analysis of the Impact of the Cycle Operation Parameters on the Wear-Out of the NMC Cell

Developing an aging model of a lithium-ion cell operating cyclically requires knowledge of the influence of individual operating parameters (temperature, charging and discharging currents, depth of discharge, and average state of charge) on the process of cell wear. A commercial 18650 lithium-nickel-manganese-cobalt (NMC) cylindrical cell with a nominal capacity of 2600 mAh was selected for the capacity consumption analysis. Taking into account that aging tests are time-consuming (especially the variants with reduced DOD may last up to several months), it was decided to carry them out under accelerated aging conditions. This means that for cyclic operating parameters, the cell was selected with values exceeding its ratings. The values of cyclic operating parameters selected during the tests are presented in Table 2. The variants related to the influence of SOC_{avg} and charging current values have been omitted. In the implemented variants, the cells were charged with a constant current of a constant average value of 0.85 C.

Table 2. Values of cyclic operating parameters of tested cell selected during aging tests.

No.	Temperature [°C]	Discharging Current [A]	Depth of Discharge [%]	Performed Cycle Number [-]
1	25	2.6	100	1800
2	25	5.2	100	1070
3	25	7.8	100	580
4	25	10.5	100	410
5	15	2.6	100	595
6	15	5.2	100	180
7	15	5.2	50	1075
8	15	7.8	100	1300
9	40	2.6	100	1170
10	40	5.2	100	678
11	40	7.8	100	395
12	40	7.8	77	776
13	40	7.8	50	1321
14	40	7.8	27	2473

The state of health of the cell is defined as the ratio of the current capacity of the C_{act} cell (determined in control conditions on the basis of relation 8) to the capacity of the new C_{new} cell. The condition for the completion of each aging test was a cell wear of 20%, which corresponds to a cell $SOH = 80\%$. After the cell reached $SOH = 80\%$, the number of complete charging cycles was noted. Capacity control measurements for each variant were performed every several dozen cycles. The control conditions are set out in Table 3.

$$SOH = \frac{C_{act}}{C_{new}} \cdot 100\% \quad (8)$$

Table 3. The test conditions for measuring cell capacity.

Parameter	Value
Ambient temperature	25 °C
Discharge current	2.6 A
Initial charging current	1.3A (CC-CV mode, at CV cell was charging till current reach 0.05% initial value)
Discharge depth	100%
Upper/lower cut-off voltage	4.2 V/2.75 V

4.1. Impact of Ambient Temperature on Cycle Life

Test results from 15 °C, 25 °C, 40 °C, 2.6A discharge current and 100% discharge depth were used to investigate the effect of ambient temperature on the cell's SOH. In these tests, the cell performed 595, 1800, and 1170 complete cycles (nos 1, 5, 9, Table 2) respectively before reaching $SOH = 80\%$. On the basis of the obtained results, it was found that the cell is characterized by higher wear at temperatures below 20 °C and above 35 °C. For this reason, we proposed to use the Gauss function (Equation 9) as a function of temperature impact (with other cyclic parameters remaining constant) on the number of cell cycles. The course of the Gauss function is shown in Figure 1.

$$N(T) = a \cdot e^{-(\frac{T-b}{c})^2} \quad (9)$$

where N is the number of cycles; T is the ambient temperature; and a, b, c are coefficients.




Figure 1. Impact of ambient temperature on cell cycle number.

4.2. Impact of Discharging Current on Cycle Life

Test results obtained at 25 °C were used to investigate the effect of the discharge current on the number of cell cycles after which the cell is considered to be worn out. In these tests, for discharge currents of 2.6, 5.2, 7.8, and 10.5 A, the cell made 1800, 1070, 580, and 410 cycles respectively (nos 1–4, Table 2). On the basis of the tests performed, the power function described in Relation 10 was selected for the discharge current because it best represented the influence of this factor on the number of cell cycles (Figure 2).

$$N(I_d) = d \cdot (I_d)^e + f \quad (10)$$

where N is the number of cycles; I_d is the discharging current; and d, e, f are model coefficients.




Figure 2. Impact of discharging current on cell cycle number.

4.3. Impact of Depth of Discharge on Cycle Life

For the analysis of the influence of DOD on the number of cell cycles, variants nos 11–14 from Table 2 were used. The ambient temperature during these tests was 40 °C and the discharge current was 7.8 A. For DOD equal to 27%, 50%, 77%, and 100%, the cell made 2473, 1321, 776, and 395 complete cycles respectively. As in the case of the discharge current, the function that best represents the influence of DOD is the power function, Equation 11, Figure 3.

$$N(DOD) = g \cdot (DOD)^h + i \quad (11)$$

where N is the number of cycles; DOD is the depth of discharge; and g, h, i are coefficients.




Figure 3. Impact of depth of discharge on cell cycle number.

4.4. Estimation of Model Coefficients

The function coefficients, 9–11, were estimated using the method of least squares. The total square error between the measured value and the value determined by the model was minimized (Equation (12)). For the obtained coefficients (Equations 9–11) this was, respectively: $8.5737e-22$, 6105, and 3038, which corresponds to a determination factor of 1, 0.9948, and 0.9988. The estimated values of the coefficients are presented in Table 4.

$$SSE = \min\left\{\sum\left(y_{meas}^2 - y_{model}^2\right)\right\} \quad (12)$$

where SSE is the sum of squares errors, y_{meas} is the measured value, and y_{model} is the value calculated from Equations 9–11.

Table 4. Results of estimation of function coefficients in eqs. 9–11.

Coefficient	Value	Coefficient	Value
a	2061	f	−2758
b	29.93	g	21180
c	13.39	h	−0.475
d	5897	i	−1959
e	−0.2683		

5. NMC Cells Wear Process Modeling Using Fuzzy Logic

Fuzzy logic is an approach belonging to multivalent logic. It assumes that there are many intermediate values between the logical zero and the logical one, which determine the degree of belonging of the element to the set. Fuzzy systems are characterized by the fact that they are knowledge-based models, which is their greatest advantage. At the same time, their implementation does not require knowledge of the details of the chemical aging reactions taking place in the cell or prior determination of function coefficients defining the impact of cyclic operating parameters on the process of cell wear, which is often very difficult. Two classes of fuzzy systems can be distinguished, the Mamdani type and the Takagi–Sugeno–Kang type [28].

5.1. Methodology of Fuzzy Modeling

The classic fuzzy system scheme consists of the following four blocks: fuzzification, inference, base of rules, and defuzzification. Its structure is presented in Figure 4.

In the fuzzification block, for each real value of input parameter, x_i , of the model, the degree of membership to individual sets of fuzzy input, A_i , is calculated. A fuzzy set in a certain space of considerations, X , is a set of pairs:

$$A_i = \{(\mu_A^*(x_i), x_i)\}, \forall x_i \in X \tag{13}$$

where μ_A is the membership function of fuzzy set A.




Figure 4. Classical structure of a fuzzy system.

Membership functions assign to each input parameter, $x_i \in X$, the degree of its belonging, $\mu_A^*(x_i)$, to a fuzzy set, assuming that $\mu_A(x_i) \in [0,1]$.

In a block of inferences on the basis of input degrees of membership $\mu_A^*(x_i)$, the resultant function of belonging is calculated $\mu_{res}(y_i)$ for each output of the y_i model. The character of the resultant function of membership is most frequently complex. Its calculation is done through reasoning, which can be mathematically realized in many ways. In order to carry out the inference operation, the inference block must contain a database of defined rules, the inference mechanism and the membership functions (B_i) of the output of the model (y). The base of rules contains logical rules that define cause and effect dependencies existing in the system between sets of fuzzy inputs and outputs. It takes the form of conditional sentences of the type:

$$\text{If } x_i \text{ is } A_i \text{ And } \dots \text{ And } x_n \text{ is } A_n \text{ Then } y_i \text{ is } B_j \text{ And } \dots \text{ And } y_m \text{ is } B_m \tag{14}$$

where x_i is the value of i-th input parameter, A_i is the i-th fuzzy set of conditions, B_j is the j-th fuzzy set of conclusions, y_i is the value of i-th output parameter, and n/m is the number of input/output parameters.

In the defuzzification block, a mechanism of defuzzification is implemented which, on the basis of the resulting function of belonging $\mu(y_i)$, determines the crisp value of each output of the y_i model. There are many methods of defuzzification, the most popular of which include the following: middle of maxima, centre of gravity, centre of sums, and the height method. For example, in the centre of gravity method, the sharp output value of model y is determined as the centre of gravity of the surface under the curve defined by this function (Figure 5), and is calculated as the quotient of the momentum of the area under the curve $\mu_{res}(y)$ relative to the vertical axis $\mu(y)$ and the size of that area. The relationship is as follows:

$$y = \frac{\int y \cdot \mu_{res}(y) dy}{\int \mu_{res}(y) dy} \tag{15}$$




Figure 5. Defuzzification by the centre of gravity method.

5.2. A Fuzzy Model of the NMC Cell Wear Process

In order to model the wear process of NMC cells (with the parameters given in Section 4) under constant load conditions, it is proposed to use a fuzzy Mamdani system. The input parameters of the model are the operating parameters of the cyclic cell (half-cycle discharge), i.e., ambient temperature, value of discharge current, and depth of discharge. The model assumes that in each half-cycle of charging, cells are charged with a constant current with a mean value of 0.85 C up to a final voltage of 4.2 V. The output parameter of the model is the number of full N cycles of charging that the cell can perform before it reaches the wear indicator equal to $SOH = 80\%$. For each input parameter of the model, three triangular membership functions were defined (Figure 6 a–c), while for the number of N cell cycles, using the results of tests presented in Section 4, nine triangular membership functions were defined (Figure 6d).

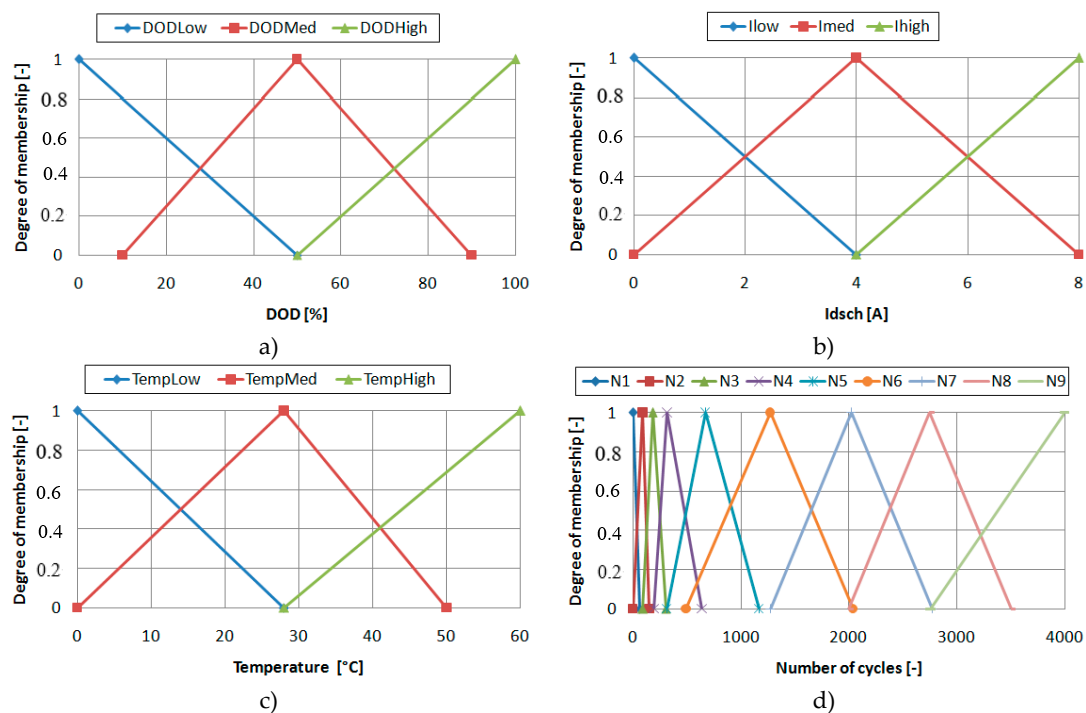


Figure 6. Membership functions of model parameters: (a) depth of discharge, (b) discharging current, (c) temperature, and (d) number of cycles.

The function of minimum (Equation 16) was assumed as t-norm operators in the inference process, whereas the function of maximum (Equation 17) was assumed as s-norm operators in the aggregation process. The centre of gravity method was used as a method of defuzzification [28].

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} \quad (16)$$

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad (17)$$

The base of rule of model contains 27 linguistic rules, based on which the number of cycles is inferred. This takes into account the measurement results (Table 2) and contains all possible combinations of functions belonging to the input parameters of the model.

An illustration of the process of applying a fuzzy model of cell wear is presented in Figure 7a–c.




Figure 7. Illustration of the inference process of the model: (a) number of cycles vs depth of discharge and temperature, (b) number of cycles vs discharging current and temperature, and (c) number of cycles vs depth of discharge and discharging current.

The developed model has been verified for six different combinations of cyclic cell operating parameters. The accuracy of the model was determined by a relative error derived from:

$$RE = \left(\frac{y_{meas} - y_{model}}{y_{meas}} \right) \cdot 100 \quad (18)$$

The verification results are summarized in Table 5.

Table 5. Verification results of NMC cell wear from fuzzy model

No.	Temperature [°C]	Discharging Current [A]	Depth of Discharge [%]	Simulated Number of Cycles [-]	Real Number of Cycles [-]	Relative Error [%]
1	25	2.6	100	1705	1800	5.60
2	40	7.8	27	2152	2473	14.89
3	40	7.8	100	433	395	8.84
4	40	7.8	50	1374	1321	3.84
5	15	2.6	100	559	595	6.37
6	15	7.8	100	1385	1300	6.13

For most of the verified variants, the relative model error is below 10%. This proves the correct operation of the fuzzy algorithm and its usefulness for predicting the aging process of cells. For the

variant $I_d = 7.8$ A, $T = 40$ °C, $DOD = 27\%$, and the relative error was 14.89%. It seems that this is a big inaccuracy, but the number of cycles performed by cells operating with reduced DOD is always many times greater than during full discharge and is often characterized by a large spread (in the case of DOD below 20%, the difference in the number of cycles performed can reach up to several thousand cycles). For this reason, all the results obtained should be considered satisfactory.

6. Conclusions

This paper describes the analyses of modeling the process of wear of 18650 lithium-ion NMC cells during cyclic operation under constant load conditions. Modeling the process of wear of NMC cells is a complex issue due to the need to take into account a large number of cyclic parameters and the correct representation of the degree of their impact. For this reason, determining the structure of the model is complex and often requires simplifying assumptions. On the basis of accelerated aging tests, the influence of discharging parameters on the process of cell capacity atrophy was investigated. In addition, functions were developed to characterize the impact of these parameters on the number of cell cycles before it reaches wear level. For ambient temperature, a new type of function reflecting the Gauss function was proposed (Equation 9), from the obtained results, the highest number of cycles a cell can perform (assuming other cyclic parameters remain constant) at a temperature close to 30 °C. In the case of discharge current and DOD values, the number of cycles depends on the power function on these parameters. The use of a fuzzy Mamdani system to reproduce the wear process of a cyclic operating cell yielded satisfactory results. For the verified variants (Table 5), in most cases the relative model error was less than 10%. In our opinion, bearing in mind the complexity of modeling the process of cell wear, this is an acceptable value.

Future research should focus on reducing model error by including charging current, SOC_{avg} , and upper cut-off voltage in the model.

Author Contributions: Conceptualization, D.B.; methodology, D.B. and L.K.; validation, L.K., D.B., and A.T.; formal analysis, A.T. and L.K.; resources, D.B.; data curation, D.B.; writing—original draft preparation, D.B. and R.P.; writing—review and editing, D.B. and L.K., and R.P.; visualization, D.B.; supervision, L.K. and A.T.

Funding: This research was funded by the Polish Government, grant number [04/42/SBAD/0483].

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Tomczewski, A.; Kasprzyk, L.; Nadolny, Z. Reduction of power production costs in a wind power plant—flywheel energy storage system arrangement. *Energies* **2019**, *12*, 1942. [[CrossRef](#)]
2. Kasprzyk, L.; Domeracka, A.; Burzyński, D. Modelling of lithium-ion batteries operation and life in electric vehicles. *Prz. Elektrotech.* **2018**, *94*, 160–163. [[CrossRef](#)]
3. Burzyński, D.; Głuchy, D.; Godek, M. Analysis of the impact of quick charge technology on the charging process parameters of the lithium-ion storage at various temperatures. In *ITM Web of Conferences*; EDP Sciences: Les Ulis, France, 2018; Volume 19.
4. Burzyński, D.; Kasprzyk, L. The operation and capacity fade modelling of the lithium-ion cell for electric vehicles. In *E3S Web of Conferences*; EDP Sciences: Les Ulis, France, 2019; Volume 108, p. 01017.
5. Burzyński, D.; Kasprzyk, L. Selected methods of modelling of the electrochemical cells operation. *Prz. Elektrotech.* **2017**, *93*, 75–78.
6. Burzyński, D.; Kasprzyk, L. Analysis of the potential use of lithium-ion energy storage in the home charging station for electric cars. In *IOP Conference Series: Earth and Environmental Science*; IOP Publishing: Bristol, UK, 2019; Volume 214, p. 012077.
7. Kasprzyk, L. Modelling and analysis of dynamic states of the lead-acid batteries in electric vehicles. *Eksploat. Niezawodn. Maint. Reliab.* **2017**, *19*, 229–236. [[CrossRef](#)]
8. Hu, X.; Li, S.; Peng, H. A comparative study of equivalent circuit models for Li-ion batteries. *J. Power Sources* **2012**, *198*, 359–367. [[CrossRef](#)]

9. Omar, N.; Monem, M.A.; Firouz, Y.; Salminen, J.; Smekens, J.; Hegazy, O.; Gaulous, H.; Mulder, G.; van den Bossche, P.; Coosemans, T.; et al. Lithium iron phosphate based battery—Assessment of the aging parameters and development of cycle life model. *Appl. Energy* **2014**, *113*, 1575–1585. [[CrossRef](#)]
10. Leng, Y.; Ge, S.; Marple, D.; Yang, X.; Bauer, C.; Lamp, P.; Wang, C. Electrochemical cycle-life characterization of high energy lithium-ion cells with thick $\text{Li}(\text{Ni}_{0.6}\text{Mn}_{0.2}\text{Co}_{0.2})\text{O}_2$ and graphite electrodes. *J. Electrochem. Soc.* **2017**, *164*, 1037–1049. [[CrossRef](#)]
11. Xu, B.; Oudalov, A.; Ulbig, A.; Andersson, G.; Kirschen, D.S. Modeling of lithium-ion battery degradation for cell life assessment. *IEEE Trans. Smart Grid* **2018**, *9*, 1131–1140. [[CrossRef](#)]
12. Huang, S.; Tseng, K.; Liang, J.; Chang, C. An online SOC and SOH estimation model for lithium-ion batteries. *Energies* **2017**, *10*, 512. [[CrossRef](#)]
13. Keil, P.; Schuster, S.F.; Wilhelm, J.; Travi, J.; Hauser, A.; Karl, R.C.; Jossen, A. Calendar aging of lithium-ion batteries. *J. Electrochem. Soc.* **2016**, *163*, A1872–A1880. [[CrossRef](#)]
14. Kaneko, G.; Inoue, S.; Taniguchi, K.; Hirota, T.; Kamiya, Y.; Daisho, Y.; Inami, S. Analysis of degradation mechanism of lithium iron phosphate battery. *World Electr. Veh. J.* **2013**, *6*, 555–561. [[CrossRef](#)]
15. Barré, A.; Suard, F.; Gérard, M.; Montaru, M.; Riu, D. Statistical analysis for understanding and predicting battery degradations in real-life electric vehicle use. *J. Power Sources* **2014**, *245*, 846–856. [[CrossRef](#)]
16. Schmalstieg, J.; Käbitz, S.; Ecker, M.; Sauer, D.U. A holistic aging model for $\text{Li}(\text{NiMnCo})\text{O}_2$ based 18,650 lithium-ion batteries. *J. Power Sources* **2014**, *257*, 325–334. [[CrossRef](#)]
17. Liu, T.; Cheng, L.; Pan, Z.; Sun, Q. Cycle life prediction of lithium-ion cells under complex temperature profiles. *Eksploat. Niezawodn. Maint. Reliab.* **2016**, *18*, 25–31.
18. Han, X.; Ouyang, M.; Lu, L.; Li, J. Cycle life of commercial lithium-ion batteries with lithium titanium oxide anodes in electric vehicles. *Energies* **2014**, *7*, 4895–4909. [[CrossRef](#)]
19. Cui, Y.; Du, C.; Yin, G.; Gao, Y.; Zhang, L.; Guan, T.; Yang, L.; Wang, F. Multi-stress factor model for cycle lifetime prediction of lithium ion batteries with shallow-depth discharge. *J. Power Sources* **2015**, *279*, 123–132. [[CrossRef](#)]
20. Kasprzyk, L. Wybrane zagadnienia modelowania ogniwo elektrochemicznych i superkondensatorów w pojazdach elektrycznych. *Pozn. Univ. Technol. Acad. J.* **2019**, *101*. [[CrossRef](#)]
21. Gao, Y.; Jiang, J.; Zhang, C.; Zhang, W.; Ma, Z.; Jiang, Y. Lithium-ion battery aging mechanisms and life model under different charging stresses. *J. Power Sources* **2017**, *356*, 103–114. [[CrossRef](#)]
22. Santhanagopalan, S.; Kim, G.H.; Keyers, M.; Pesaran, A.; Smith, K.; Neubauer, J. Battery life. In *Design and Analysis of Large Lithium-Ion Battery Systems*; Artech House: London, UK, 2015; pp. 81–93.
23. Jossen, A. Fundamentals of battery dynamics. *J. Power Sources* **2006**, *154*, 530–538. [[CrossRef](#)]
24. Birkl, C.R.; Roberts, M.R.; McTurk, E.; Bruce, P.G.; Howey, D.A. Degradation diagnostics for lithium ion cells. *J. Power Sources* **2017**, *341*, 373–386. [[CrossRef](#)]
25. Bach, T.C.; Schuster, S.F.; Fleder, E.; Müller, J.; Brand, M.J.; Lormann, H.; Jossen, A.; Sextl, G. Nonlinear aging of cylindrical lithium-ion cells linked to heterogeneous compression. *J. Energy Storage* **2016**, *5*, 212–223. [[CrossRef](#)]
26. Schuster, S.F.; Bach, T.; Fleder, E.; Müller, J.; Brand, M.; SEXTL, G.; Jossen, A. Nonlinear aging characteristics of lithium-ion cells under different operational conditions. *J. Energy Storage* **2015**, *1*, 44–53. [[CrossRef](#)]
27. Wang, J.; Purewal, J.; Liu, P.; Hicks-garner, J.; Soukazian, S.; Sherman, E.; Sorenson, A.; Vu, L.; Tataria, H.; Verbrugge, M.W. Degradation of lithium ion batteries employing graphite negatives and nickel-cobalt-manganese oxide + spinel manganese oxide positives: Part 1, aging mechanisms and life estimation. *J. Power Sources* **2014**, *269*, 937–948. [[CrossRef](#)]
28. Zadeh, L.A. The concept of a linguistic variable and its application to approximate reasoning—I. *Inf. Sci.* **1975**, *8*, 199–249. [[CrossRef](#)]



OŚWIADCZENIE WSPÓŁAUTORÓW ARTYKUŁU

My, niżej podpisani, oświadczamy, że:

- 1) jesteśmy współautorami artykułu naukowego pt. **A novel method for the modelling of the state of health of lithium-ion cells using machine learning for practical applications**
- 2) wydanego w¹ **Knowledge-Based Systems** (<https://doi.org/10.1016/j.knosys.2021.106900>) w roku 2021 ;
- 3) procentowy udział pracy wykonanej podczas przygotowywania artykułu oraz zakres zadań przyporządkowanych do poszczególnych artykułów jest zamieszczony poniższej tabeli;

Lp.	Imię i nazwisko	Afiliacja	Procentowy udział ²
1.	Damian Burzyński	Politechnika Poznańska	90%
2.	Leszek Kasprzyk	Politechnika Poznańska	10%

¹ nazwa czasopisma, monografii lub zbioru materiałów pokonferencyjnych

² suma winna wynosić 100%

4) szczegółowy opis udziału autorów w przygotowaniu przedmiotowej publikacji jest następujący:

a) imię i nazwisko: Damian Burzyński,

zakres prac³: opracowanie koncepcji pracy, wybór metodyka badań, zaplanowanie i wykonanie badań, wykonanie modelu i przeprowadzenie symulacji, analiza wyników, analiza statystyczna, przegląd literatury, wykonanie rysunków oraz formatowanie i redakcja tekstu przed złożeniem pracy do druku.

b) imię i nazwisko: Leszek Kasprzyk,

zakres prac: zaplanowanie badań, analiza wyników, opracowanie i napisanie wniosków, konsultacja i opieka.

5) podane informacje są zgodne ze stanem faktycznym.

Niniejsze oświadczenie zostało sporządzone w 2 jednobrzmiących egzemplarzach.

Burzyński
Kasprzyk
.....
.....
.....
.....

podpisy współautorów

³ przykładowe nazwy zadań: koncepcja pracy, postawienie hipotez, redakcja pracy, zaplanowanie badań, wybór metodyki badań, graficzne przedstawienie wyników, prowadzenie badań, zbieranie piśmiennictwa, zbieranie danych, konsultacja i opieka, analiza statystyczna, korekta pracy przed złożeniem do druku, interpretacja wyników, wnioski z pracy, zdobywanie środków finansowych

OŚWIADCZENIE WSPÓŁAUTORÓW ARTYKUŁU

My, niżej podpisani, oświadczamy, że:

- 1) jesteśmy współautorami artykułu naukowego pt. **Analysis and modelling of the wear-out process of a lithium-nickel-manganese-cobalt cell during cycling operation under constant load conditions** ✓
- 2) wydanego w¹ **Energies (SI: Electrochemical Energy Conversion and Storage Technologies 2019)** w roku 2019 ;
- 3) procentowy udział pracy wykonanej podczas przygotowywania artykułu oraz zakres zadań przyporządkowanych do poszczególnych artykułów jest zamieszczony poniższej tabeli;

Lp.	Imię i nazwisko	Afiliacja	Procentowy udział ²
1.	Damian Burzyński	Politechnika Poznańska	64%
2.	Leszek Kasprzyk	Politechnika Poznańska	12%
3.	Robert Pietracho	Politechnika Poznańska	16%
4.	Andrzej Tomczewski	Politechnika Poznańska	8%

¹ nazwa czasopisma, monografii lub zbioru materiałów pokonferencyjnych

² suma winna wynosić 100%

4) szczegółowy opis udziału autorów w przygotowaniu przedmiotowej publikacji jest następujący:

a) imię i nazwisko: Damian Burzyński,

zakres prac³: opracowanie koncepcji pracy, opisanie procesów starzeniowych oraz metodyki modelowania zużycia się ogniwa litowo-jonowego, zaplanowanie i wykonanie badań, wykonanie modelu i przeprowadzenie symulacji, analiza wyników, analiza statystyczna, przegląd literatury, wykonanie rysunków oraz formatowanie i redakcja tekstu przed złożeniem pracy do druku.

b) imię i nazwisko: Leszek Kasprzyk,

zakres prac: opisanie procesów starzeniowych oraz metodyki modelowania zużycia się ogniwa litowo-jonowego, zaplanowanie badań, analiza wyników, analiza statystyczna, opracowanie i napisanie wniosków, konsultacja i opieka.

c) imię i nazwisko: Andrzej Tomczewski,

zakres prac: konsultacja i opieka, opracowanie i napisanie wniosków, analiza wyników.

d) imię i nazwisko: Robert Pietracho,

zakres prac: przegląd literatury, wykonanie rysunków formatowanie i redakcja tekstu przed złożeniem pracy do druku.

5) podane informacje są zgodne ze stanem faktycznym.

Niniejsze oświadczenie zostało sporządzone w 4 jednobrzmiących egzemplarzach.


.....

.....

.....

.....

podpisy współautorów

³ przykładowe nazwy zadań: koncepcja pracy, postawienie hipotez, redakcja pracy, zaplanowanie badań, wybór metodyki badań, graficzne przedstawienie wyników, prowadzenie badań, zbieranie piśmiennictwa, zbieranie danych, konsultacja i opieka, analiza statystyczna, korekta pracy przed złożeniem do druku, interpretacja wyników, wnioski z pracy, zdobywanie środków finansowych