

Model predykcji stanu dostępnej energii ogniw litowo-żelazowo-fosforanowych

Streszczenie. W artykule zajęto się problemem predykcji stanu dostępnej ogniw litowo-żelazowo-fosforanowych (LFP) z wykorzystaniem technik uczenia maszynowego. Omówiono realizowaną wiele miesięcy procedurę eksperymentalną oraz przedstawiono wyniki dla 12 ogniw pracujących cyklicznie w różnych warunkach temperaturowych i obciążeniowych. Zaprezentowano koncepcję modelu predykcji stanu dostępnej energii wraz z jego weryfikacją. Skuteczność proponowanej metody potwierdzono uzyskując średni błąd na poziomie 5%.

Abstract. The paper deals with the problem of state of available energy prediction for a lithium-iron-phosphate (LFP) cell using machine learning techniques. The experimental procedure which was carried out for many months is discussed and the results for 12 cells operating cyclically under different temperature and load conditions are presented. The concept of a model for predicting the state of available energy is presented, along with its verification. The effectiveness of the proposed method was confirmed by obtaining an average error of 5%. (**State of available energy prediction model for lithium-iron-phosphate cells**).

Słowa kluczowe: ogniwo litowo-jonowe, trwałość akumulatora, uczenie maszynowe, modelowanie trwałości.

Keywords: lithium-ion cell, battery life, machine learning, cycle life modeling.

Wstęp

W ostatnich latach nastąpił gwałtowny przyrost zapotrzebowania na urządzenia służące do magazynowania energii elektrycznej. Spośród wielu typów zasobników energii elektrycznej największą popularnością cechują się obecnie ogniwa elektrochemiczne na bazie litu. Pakiety tych ogniw mają w dzisiejszych czasach szerokie zastosowania w sektorze elektroenergetyki [1], elektromobilności [2-4], odnawialnych źródeł energii [5,6], a także w urządzeniach elektronicznych codziennego użytku.

Jednym z najważniejszych aspektów użytkowania ogniw litowo-jonowych obecnie jest ich trwałość, co wynika z wysokich kosztów tych magazynów. Jest to problem szczególnie istotny w sektorze elektromobilności, ponieważ pakiet ogniw litowo-jonowych jest najczęściej najdroższym elementem pojazdów elektrycznych.

Z tego powodu projektanci systemów zasilanych z pakietów akumulatorów muszą analizować zachowanie się ogniw w różnych warunkach pracy, w celu uzyskania informacji o przewidywanej zdolności ogniw do dostarczenia zadanej energii lub mocy [7,8], przewidywanego czasu działania tych systemów, jak również o możliwości wystąpienia stanów awaryjnych. Z drugiej strony nieprawidłowa eksploatacja ogniw będzie skutkowała przyspieszoną degradacją i koniecznością ich recyklingu [9-11].

Degradacja ogniw spowodowana jest przez zachodzące procesy starzeniowe, przede wszystkim podczas pracy, jak również podczas stanu jałowego. Zależy ona od wielu parametrów takich jak wartości prądów ładowania i rozładowania, temperatury otoczenia, głębokości rozładowania, aktualnego stanu zużycia oraz stanu naładowania [12,13]. Należy podkreślić, iż niektóre z wymienionych wyżej parametrów są ze sobą skorelowane i ich wpływ na stan dostępnej energii jest nieliniowy. Ogniwa litowo-żelazowo-fosforanowe mogą pracować wiele lat, co sprawia, że analiza i przewidywanie stanu dostępnej energii na przestrzeni całego okresu eksploatacji jest skomplikowana i wymaga zastosowania zaawansowanych metod.

Od ostatnich kilkunastu lat zagadnienie modelowania parametrów związanych z degradacją ogniw litowo-jonowych jest tematem często podejmowanym w wielu ośrodkach badawczych na całym świecie [14-21]. Chociaż do dnia dzisiejszego rozwinięto wiele modeli różnymi

metodami, to ze względu na stopień trudności obszar przewidywania stanu dostępnej energii ogniw w dalszym ciągu nie został dostatecznie zbadany.

Procedura eksperymentalna

W celu zbadania procesu degradacji ogniw przeprowadzono wielomiesięczną procedurę eksperymentalną, podczas której ogniwa pracowały cyklicznie w różnych warunkach obciążeniowych i temperaturowych. Do badań wybrano komercyjne ogniwo litowo-żelazowo-fosforanowe (LFP) firmy A123Systems APR18650 m1A o parametrach zestawionych w tabeli 1.

Tabela 1. Parametry badanego ogniwa

Parametr	Wartość
Typ	LiFePO ₄
Napięcie znamionowe (U_{nom})	3,3 V
Pojemność znamionowa	1100 mAh
Ładowanie standardowe	1,5 A CC-CV
Ładowanie szybkie	4 A CC-CV
Maksymalny ciągły prąd rozładowania	30 A
Trwałość (prąd 5C, 100% DOD)	>1000 cykli
Napięcie odcięcia w 25°C	3,6 V ładowanie 2,0 V rozładowanie
Masa	39 g
Zakres temperatur podczas pracy	-30°C do +60°C

Badania starzeniowe przeprowadzono na zbiorze 12 ogniw, które zostały poddane unikalnym procedurom starzeniowym – listę przeprowadzonych wariantów badań zestawiono w tabeli 2. W trakcie badań do zachowania stałej temperatury podczas pracy cyklicznej ogniw wykorzystano komorę temperaturową Panasonic MIR-254. Zakres zastosowanych temperatur otoczenia zawierał się w przedziale od +10°C do +40°C (5 ogniw przetestowano w 10°C, 1 ogniwo w 15°C, 4 ogniwa w 25°C oraz 2 ogniwa w 40°C). Podczas półcyklu rozładowania ogniwa były obciążane metodą CC (stały prąd) w zakresie od 1,1 A (1C) do 6,6 A (6C) w pełnym zakresie napięcia – określonego przez producenta ogniwa (tab. 1) – co odpowiada głębokości rozładowania DOD=100%. Dla wszystkich ogniw zastosowano jednakową procedurę ładowania CC-CV (stały prąd – stałe napięcie) o wartości początkowej prądu 3,3 A (3C) i odcięcia po osiągnięciu 150 mA w fazie stałego napięcia (0,045C). Półcykle ładowania i rozładowania realizowane były z wykorzystaniem aparatury przeznaczonej do testowania

ogniwi elektrochemicznych. Podczas całej procedury eksperymentalnej rejestrowano temperaturę w punkcie środkowym obudowy ogniwa (sondy Pt100). Ogniwa eksploatowane były w zakresie stopnia zużycia (SOH) typowego dla magazynów energii stosowanych w pojazdach elektrycznych, tj. od SOH=100% do SOH=80% [22-24]. Podczas badań SOH ogniwa wyznaczano średnio co 48 godzin zgodnie z przedstawioną poniżej procedurą kontrolną oraz z wykorzystaniem zależności (1):

1. Zakończenie pracy cyklicznej po zakończonym półcyklu rozładowania.
2. Ustalenie temperatury ogniwa na poziomie $25 \pm 1^\circ \text{C}$.
3. Standardowe ładowanie ogniwa (do osiągnięcia prądu 30 mA w fazie CV).
4. Przerwa: 5 sekund.
5. Rozładowanie stałym prądem 1,1 A (1C) do 2,0 V.
6. Zliczenie oddanego ładunku (Q_{d_i}) metodą Coulomb counting.

$$(1) \quad SOH = \frac{Q_{d_i}}{Q_{d_1}} \cdot 100\%$$

gdzie: SOH – stopień zużycia ogniwa [%], Q_{d_i} – oddany ładunek podczas i -tej procedury kontrolnej [mAh], Q_{d_1} – oddany ładunek dla nowego ogniwa [mAh].

Analiza uzyskanych wyników

W niniejszej pracy przedmiotem analizy był stan dostępnej energii (SOE) możliwej do wymiany podczas pełnego cyklu pracy ogniwa w rozważanym zakresie eksploatacji:

$$(2) \quad SOE_i = \frac{U_{d_{ave}} \cdot Q_d + U_{ch_{ave}} \cdot Q_{ch}}{2 \cdot U_{nom} \cdot Q_{nom}}$$

gdzie: SOE_i – stan dostępnej energii ogniwa w i -tym cyklu pracy [-], Q_d – oddany ładunek podczas półcyklu rozładowania [mAh], $U_{d_{ave}}$ – średnie napięcie ogniwa podczas półcyklu rozładowania [V], Q_{ch} – oddany ładunek podczas półcyklu ładowania [mAh], $U_{ch_{ave}}$ – średnie napięcie ogniwa podczas półcyklu ładowania [V], U_{nom} – napięcie znamionowe [V], Q_{nom} – ładunek znamionowy (1100 mAh).

W celu uwzględnienia dotychczasowej degradacji ogniwa wyznaczano ich liczbę cykli ekwiwalentnych (FEC) na podstawie wzoru:

Tabela 2. Wykaz wariantów procedury eksperymentalnej


Lp.	Symbol ogniwa	Temperatura otoczenia [°C]	Prąd rozładowania [A]	FEC [-]	SOE_{OL} [-]	SOE_E [-]	Liczba cykli N [-]
1	J1	10	1C	1164	0,86	0,60	1476
2	E13	10	3C	1085	0,81	0,59	1555
3	G3	10	4C	983	0,82	0,60	1394
4	H6	10	5C	878	0,78	0,55	1323
5	C30	10	6C	763	0,76	0,53	1142
6	E4	15	3C	2138	0,84	0,63	2817
7	F8	25	3C	5204	0,88	0,67	6513
8	E9	25	4C	2017	0,84	0,66	2671
9	E6	25	6C	809	0,80	0,55	1206
10	E11	40	3C	2506	0,91	0,75	2939
11	F14	40	5C	626*	0,84	-	762*
12	E10	25	2C	995*	0,88	-	1098*

* – warianty przerwane (F14 przy SOH = 95,9%, E10 przy SOH=99,1%)

$$(3) \quad FEC = \sum_1^N SOE_i$$

gdzie: FEC – liczba cykli ekwiwalentnych [-], N – liczba cykli pracy [-].

Wykorzystując zależności (2)-(3) wyznaczono SOE oraz FEC dla wszystkich testowanych ogniwa, a wyniki przedstawiono na rysunku 1.



Rys. 1. Stan dostępnej energii w rozpatrywanym okresie eksploatacji badanych ogniwa. Okręgami oznaczono fazy przyspieszonej degradacji.

Uzyskane wyniki dowodzą, iż ogniwa pracujące cyklicznie w różnych warunkach obciążeniowych i temperaturowych różnią się stanem dostępnej energii. Ponadto w zależności od parametrów cyklu pracy i wykonanej liczby cykli pracy SOE może charakteryzować się zmiennością w trakcie rozpatrywanego okresu eksploatacji. Na podstawie przeprowadzonych analiz stwierdzono, iż ogniwa pracujące cyklicznie w temperaturach (25°C , 40°C) posiadają wyższy stan dostępnej energii zarówno na początku (SOE_{BOL}) jak i na końcu okresu eksploatacji (SOE_{EOL}) w porównaniu do ogniwa pracujących w niższych temperaturach (10°C , 15°C). Dla większości testowanych wariantów szybkość degradacji była w przybliżeniu liniowa. Zaobserwowano, iż dla ogniwa „J1”, „E11” oraz „F8” po fazie w przybliżeniu liniowej degradacji następuje faza przyspieszonej degradacji. Zjawisko to wystąpiło po około 4290 FEC dla ogniwa „F8”, 2060 FEC dla „E11” oraz 930 FEC dla „J1” i zostało oznaczone okręgami na rys. 1. Spośród zrealizowanych wariantów badań najwyższą utratą zdolności do wymiany energii podczas cyklu pracy charakteryzowały się ogniwa rozładowywane najwyższym prądem (6C) oraz w najniższej temperaturze otoczenia (10°C). Na przykład stan dostępnej energii ogniwa „J1” (temperatura otoczenia 10°C , prąd rozładowania 1C) na początku okresu eksploatacji wynosił $SOE_{BOL} = 0,86$ i spadł o 0,26 po przekroczeniu SOH=80%. Drugim w kolejności najwyższym spadkiem SOE charakteryzowało się ogniwo „E6” (temperatura otoczenia 25°C , prąd rozładowania 6C) i wyniósł on 0,25.

Model predykcji SOE

Zaprezentowane wyniki świadczą o tym, że ogniwa pracujące w różnych warunkach obciążeniowych, temperaturowych, przy tym samym stanie zużycia, mogą znacznie się różnić stanem dostępnej energii. Ponadto szybkość degradacji w zależności od wartości parametrów pracy cyklicznej może być zmienna – a określenie punktów

zmienności jest wysoce skomplikowane. Tym samym fakt, ten potwierdza złożoność zaprezentowanego problemu.

Na tej podstawie Autorzy do odwzorowania SOE ogniwa w rozpatrywanym okresie eksploatacji proponują zastosowanie metod opartych na wiedzy. W odróżnieniu od modeli matematycznych, struktury modeli z tej grupy metod są ściśle dopasowane do danych uczących i tworzą w praktyce struktury niemożliwe do zinterpretowania przez człowieka. Z drugiej strony najważniejszymi zaletami tej metody jest brak konieczności znajomości rozkładów parametrów modelu oraz występujących korelacji między nimi, a także wysoka dokładność predykcji nawet w przypadku zbioru uczącego o niewielkich rozmiarach. Spośród metod opartych na wiedzy wyróżnić należy metody uczenia maszynowego obejmujące między innymi: drzewa regresji, maszyny wektorów wspierających (SVM), regresję opartą na procesach Gaussowskich (GPR), jak również sieci neuronowe. W niniejszej pracy Autorzy dokonali porównania różnych modeli z grupy metod uczenia maszynowego z nadzorem.

Dla każdego modelu zastosowano identyczną strukturę parametrów wejściowych i parametru wyjściowego. Parametrami wejściowymi były: temperatura otoczenia, wartość prądu rozładowania oraz dotychczasowy stan zużycia wyrażony poprzez wymienioną energię ogniwa podczas ładowania i rozładowania. Parametrem wyjściowym modelu był aktualny stan dostępnej energii. Spośród przebadanych ogniw do zestawu uczącego wybrano ogniwa pracujące cyklicznie w różnych temperaturach i przy różnych wartościach prądu obciążenia („J1”, „E13”, „H6”, „C30”, „F8”, „E6” oraz „E11”) – tworząc tym samym 211 unikalnych zestawów danych. Do weryfikacji modeli wykorzystano następujące ogniwa: „F14”, „E10”, „G3”, „E4” oraz „E9” – uzyskując 89 zestawów danych testowych. Do weryfikacji wykorzystano średni procentowy błąd bezwzględny (MAPE) opisany zależnością (4). Podsumowując, cały zestaw danych został podzielony według proporcji: 70% - dane uczące, 30% dane testowe. Wyniki procesu uczenia zestawiono w tabeli 3.

$$(4) \quad MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - f_i}{y_i} \right| \cdot 100\%$$

gdzie: y_i – wartość zmierzona [-], f_i – wartość modelu [-], n – liczba próbek [-].

Tabela 3. Wyniki procesu uczenia

Nr modelu	Typ modelu	Cechy modelu	MAPE [%]
1	Sieć neuronowa	Liczba warstw: 1 Liczba neuronów: 10	0,54
2	Sieć neuronowa	Liczba warstw: 1 Liczba neuronów: 25	0,44
3	Sieć neuronowa	Liczba warstw: 1 Liczba neuronów: 100	0,35
4	Sieć neuronowa	Liczba warstw: 2 Liczba neuronów: 10*	0,37
5	Sieć neuronowa	Liczba warstw: 3 Liczba neuronów: 10*	0,38
6	GPR	Funkcja bazowa: stała Kernel: f. kwadratowa	0,32
7	GPR	Funkcja bazowa: stała Kernel: f. wykładnicza	0,32
8	GPR	Funkcja bazowa: stała Kernel: f. Matern 5/2	0,31
9	SVM	Kernel: f. Gaussowska Parametr skali: 0,43	1,04
10	Drzewa regresji	Rozmiar liścia: 8 Liczba próbek: 30	1,9

* - liczba neuronów we wszystkich warstwach była jednakowa


Spośród testowanych modeli najwyższym dopasowaniem charakteryzuje się model regresji opartej na procesach Gaussowskich dla stałej funkcji bazowej oraz dla funkcji jądrowej typu Matern 5/2 (5):

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

gdzie: σ_l – długość charakterystyczna [-], r – odległość Euklidesowa między próbkami x oraz x' [-], σ_f – odchylenie standardowe [-].

Opracowany model odwzorowuje zestaw uczący z błędem MAPE = 0,31% (wartości parametrów modelu wynoszą $\sigma_l = 0,91884$ oraz $\sigma_f = 0,1652$). Modele oparte o sieci neuronowe charakteryzują się błędem zbliżonym do modeli GPR, pod warunkiem zastosowania dużej liczby warstw lub neuronów. Z kolei modele SVM oraz drzewa regresji wykazują błąd wielokrotnie wyższy (SVM ponad trzykrotnie, drzewa regresji ponad sześciokrotnie) w porównaniu do modeli GPR.

W następnej części badań opracowany model (nr 8 z tab. 3) został zweryfikowany na podstawie ogniwa pracujących cyklicznie, które nie były wykorzystane podczas procedury uczenia. Weryfikacja polegała na porównaniu predykcji SOE modelu z wartością obliczoną na podstawie rzeczywistych pomiarów w całym zakresie eksploatacji ogniwa. Średni procentowy błąd bezwzględny dla wszystkich próbek zestawu testowego wyniósł 5%. Największa rozbieżność między wartością rzeczywistą i predykowaną przez model występowała w zakresie wysokich FEC (ogniwa „E9”, „E10” oraz „E4”) – powyżej 900 FEC. Natomiast dla ogniwa „F14” rozbieżność w całym zakresie eksploatacji była w przybliżeniu stała. Uzyskane wyniki zestawiono w tabeli 4, a przykładową charakterystykę porównawczą przedstawiono na rysunku 2.



Rys.2. Przykładowa charakterystyka porównawcza SOE wyznaczonego przez model GPR z wartością obliczoną na podstawie rzeczywistych pomiarów dla ogniwa „G3”. Uzyskana wartość błędu MAPE = 2,80%.

Tabela 4. Wyniki weryfikacji modelu predykcji SOE

Symbol ogniwa	MAPE [%]
F14	6,60
E10	3,53
G3	2,80
E14	7,11
E9	4,22

Wnioski

W artykule zaprezentowano koncepcję modelu predykcji stanu dostępnej energii (SOE) możliwej do wymiany podczas pełnego cyklu pracy dla ogniwa litowo-żelazowo-

fosforanowego (LFP). Opracowany model wykorzystuje techniki uogólniania wiedzy i uwzględnia zmienność warunków pracy cyklicznej oraz dotychczasową degradację ogniwa (wyrażoną liczbą wykonanych ekwiwalentnych cykli pracy). Przedstawiona w pracy metoda umożliwia uzyskanie predykcji SOE przy średnim poziomie błędu równym 5%. Biorąc pod uwagę małą liczbę ogniw w zbiorze uczącym (7 ogniw pracujących cyklicznie w unikalnych warunkach) uzyskana dokładność modelu zdaniem Autorów jest wysoka. Kolejną zaletą proponowanej metody jest brak wymogu określania struktury modelu – jest ona ściśle dopasowana do zestawu danych – co jest szczególnie istotne w przypadku ogniw elektrochemicznych, dla których wpływ parametrów pracy cyklicznej na parametry określające degradację jest nieliniowy.

Przedstawiona metodyka może być wykorzystana dla innych ogniw litowo-jonowych, jak również dla ogniw o innym składzie chemicznym (po zmodyfikowaniu procedury eksperymentalnej). Opracowany model charakteryzuje się wysokim potencjałem aplikacyjnym, przede wszystkim w systemach zarządzania pracą akumulatorów. Może stanowić on element optymalizacji pracy pakietów ogniw prowadząc do spadku degradacji ogniw w długim okresie czasu.

Praca badawcza została sfinansowana z Subwencji Badawczej nr 0212/SBAD/0512.

Autorzy:

dr inż. Damian Burzyński, Politechnika Poznańska, Instytut Elektrotechniki i Elektroniki Przemysłowej, ul. Piotrowo 3a, 60-965 Poznań, E-mail: damian.burzynski@put.poznan.pl;
dr hab. inż. Leszek Kasprzyk, prof. PP; Politechnika Poznańska, Instytut Elektrotechniki i Elektroniki Przemysłowej, ul. Piotrowo 3a, 60-965 Poznań, E-mail: leszek.kasprzyk@put.poznan.pl.

LITERATURA

- [1] Edström K. et al., Battery 2030+ Inventing the Sustainable Batteries of the Future: Research Needs and Future Actions, *Roadmap paper*, (2020)
- [2] Pietracho R., Wenge C., Balischewski S., Lombardi P., Komarnicki P., Kasprzyk L., and 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*, 14, (2021), No 17, 5327
- [3] Tomczewski A., Mikulski S., Piotrowski A., Sowa S., Wróbel K., Multicriteria Optimisation of the Structure of a Hybrid Power Supply System for a Single-Family Housing Estate in Poland, Taking into Account Different Electromobility Development Scenarios, *Energies*, 16, (2023), No 10, 4132
- [4] Pietracho R., Wenge C., Komarnicki P., Kasprzyk L., Multi-Criterial Assessment of Electric Vehicle Integration into the Commercial Sector – A Case Study, *Energies*, 16, (2023), No 1, 462
- [5] Hałuszczak B., Putz Ł., Dobrzycki A., Mikulski S., Hybrid OFF-GRID installation as the as the power supply of summer house, *Przegląd Elektrotechniczny*, 98 (2022), nr 11, 248-252
- [6] Dobrzycki A., Kurz D., Maćkowiak E., Influence of Selected Working Conditions on Electricity Generation in Bifacial Photovoltaic Modules in Polish Climatic Conditions, *Energies*, 14, (2021), No 16, 4964
- [7] Kasprzyk L., Bednarek K., Burzyński D., Symulacja pracy akumulatorów kwasowo-ołowiowych, *Przegląd Elektrotechniczny*, 92, (2016), nr 12, 61-64
- [8] Burzyński D., Kasprzyk L., Wybrane metody modelowania pracy ogniw elektrochemicznych, 93, (2017), nr 12, 75-78
- [9] Jajczyk J., Filipiak M., Dąbrowski T., Reducing the Use of Electrochemical Sources of Electricity Through the Use of Wireless Power Supply, *Rocznik Ochrona Środowiska*, 22, (2020), No 1, 444-455
- [10] Kujawińska A., Hamrol A., Brzozowski K., Minimizing the emission of material waste in the production process of batteries, *Bulletin of the Polish Academy of Sciences Technical Sciences*, 70, (2022), No 6, 144049
- [11] Kasprzyk L., Burzyński D., Lewandowska A., Pietracho R., Szymenderski J., Wenge C., Modelling the operation of fuel cells in hydrogen vehicles, *Przegląd Elektrotechniczny*, 97, (2021), nr 12, 117-120
- [12] 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, *Computer Applications in Electrical Engineering*, (2018), No 19, 01035
- [13] Kasprzyk L., Domeracka A., Burzyński D., Modelling of lithium-ion batteries operation and life in electric vehicles, *Przegląd Elektrotechniczny*, 94, (2018), nr 12, 158-161
- [14] Barre A., Suard F., Gerard M., Montaru M., Riu D., Statistical analysis for understanding and predicting battery degradations in real-life electric vehicle use, *Journal of Power Sources*, 245, (2014), 846-856
- [15] Schuster S., Bach T., Fleider E., Muller J., Brand M., Sextl G., Jossen A., Nonlinear aging characteristics of lithium-ion cells under different operational conditions, *Journal of Energy Storage*, 1, (2015), 44-53
- [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*, 268, (2014), 658-669
- [17] Kaneko G., Inoue S., Taniguchi K., Hirota T., Kamiya Y., Daisho Y., Inami S., Analysis of Degradation Mechanism of Lithium Iron Phosphate Battery, *World Electric Vehicle Journal*, 6, (2013), No 3, 555-561
- [18] 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*, 8, (2020), 52796-52814
- [19] Richardson R., Osborne M., Howey D., Gaussian process regression for forecasting battery state of health, *Journal of Power Sources*, 357, (2017), 209-219
- [20] Wang Y., Zhang C., Chen Z., A method for joint estimation of state-of-charge and available energy of LiFePO4 batteries, *Applied Energy*, 135, (2014), 81-87
- [21] Li X., Pan K., Fan G., Lu R., Zhu Ch., Rizzoni G., Canova M., 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*, 367, (2017), 202-213
- [22] Yang D., Wang Y., Pan R., Chen R., Chen Z., A Neural Network Based State-of-Health Estimator of Lithium-ion Battery in Electric Vehicles, *Energy Procedia*, 105, (2017), 2059-2064
- [23] Guo J., Li Z., Pecht M., A Bayesian approach for Li-Ion battery capacity fade modeling and cycles to failure prognostics, *Journal of Power Sources*, 281, (2015), 173-184
- [24] Schulze M., Neale N., Half-Cell Cumulative Efficiency Forecasts Full-Cell Capacity Retention in Lithium-Ion Batteries, *ACS Energy Letters*, 6, (2021), No 3, 1082-1086