

**EVALUAREA STĂRII DE DEGRADARE A BATERIILOR REÎNCĂRCABILE ÎN
SISTEME ALIMENTATE CU BATERII**

Teză de doctorat – Rezumat

pentru obținerea titlului științific de doctor la

Universitatea Politehnica Timișoara

în domeniul de doctorat Calculatoare și Tehnologia Informației

autor ing. Lucian UNGUREAN

conducător științific Prof.univ.dr.ing. Mihai V. Micea

luna Noiembrie 2021

Cuprins

1.	Introducere	2
1.1	Domeniile și tema cercetării.....	2
1.2	Obiective propuse.....	2
1.3	Structura lucrării.....	3
2.	Noțiuni teoretice.....	3
3.	Stadiul actual al cercetării	3
4.	Metoda de estimare a stării de degradare a bateriilor bazată pe regresie polinomială.....	4
5.	Metodă de estimare a stării de degradare a bateriilor bazată pe rețele neuronale de tip GRU	6
6.	Sistem cadru de evaluare a performanțelor metodelor de estimare a stării de degradare a bateriilor bazate pe rețele neuronale.....	7
7.	Evaluarea performanțelor	8
8.	Concluzii și perspective	10

1. Introducere

Datorită avansului tehnologic numărul sistemelor alimentate cu bateri a cunoscut o creștere rapidă. Din acest motiv, monitorizarea stării de degradare a bateriei precum și estimarea timpului rămas de utilizare a devenit o problemă importantă.

Sistemele de management al bateriilor joacă un rol important în acest context, ele dezvoltându-se de la simple sisteme de monitorizare a încărcării și descărcării bateriilor până la sisteme complexe care monitorizează multiplii parametri ai bateriei și oferă estimări în legătură cu starea de sănătate a acesteia.

1.1 Domeniile și tema cercetării

Teza de față tratează probleme dintr-o multitudine de domenii interconectate, dintre care cele mai importante sunt:

- Domeniul bateriilor - un domeniu complex care a cunoscut o evoluție accelerată în ultimul deceniu datorită progresului tehnologicilor de fabricare a compușilor chimici;
- Domeniul sistemelor încorporate alimentate cu baterii reîncărcabile - un domeniu extins ce a cunoscut o creștere exponențială datorită evoluției tehnologice din domeniul bateriilor - având o plajă de aplicabilitate în toate domeniile de activitate: militar, aeronautic, automotive, medical, produse electronice de larg consum.

Având în vedere aceste două domenii principale, cercetarea abordează următoarele subdomenii:

- Subdomeniul sistemelor de management al bateriilor;
- Subdomeniul metodelor de estimare a stării de degradare a bateriilor - un domeniu nou care prezintă un interes deosebit, fapt demonstrat prin numărul mare de publicații recente;
- Subdomeniul inteligenței artificiale - un domeniu vast, cu o vechime de peste 60 de ani care a cunoscut de-a lungul timpului o creștere spectaculoasă susținută de evoluția puterii de calcul.

Tema lucrării de cercetare elaborată în această teză este evaluarea stării de degradare a bateriilor reîncărcabile în sisteme alimentate cu baterii.

1.2 Obiective propuse

Principalul scop al acestei teze de doctorat este găsirea unor soluții pentru îmbunătățirea sau chiar rezolvarea unor probleme actuale în cadrul metodelor de estimare a stării de degradare a bateriilor. Activitatea de cercetare are ca principale obiective:

- Definirea unor metode de estimare a stării de degradare al bateriilor reîncărcabile care să prezinte un nivel ridicat de performanță și de eficiență, adică:
 - o o acuratețe de estimare cât mai ridicată în ceea ce privește SoH, respectiv
 - o să poată fi implementate și executate pe platforme digitale încorporate, cu resurse limitate (de memorie, de procesare, consum de energie, etc.).

- Definirea unui cadru de evaluare a performanțelor metodelor de estimare a SoH, care să cuprindă:
 - o criterii de precizie și acuratețe,
 - o criterii de evaluare a complexității algoritmilor,
 - o criterii de evaluare a resurselor de microprocesor utilizare precum și a consumului propriu de energie al algoritmului.

1.3 Structura lucrării

Structura lucrării este prezentată în cele ce urmează.

Capitolul 2 cuprinde câteva noțiuni teoretice care sunt folosite în domeniul cercetării curente. Printre cele mai importante noțiuni sunt: descrierea și structura unui sistem de management al bateriilor, definirea stării de degradare a bateriilor, modele de baterii și câteva noțiuni despre rețele neuronale folosite în estimarea seriilor de timp.

Capitolul 3 conține o descriere detaliată a abordărilor curente în ceea ce privește metodele de evaluare a stării de degradare a bateriilor. Descrierea metodei propuse pentru estimarea SoH pe baza regresiei polinomiale, este cuprinsă în capitolul 4. Capitolul 5 conține detalii despre o nouă metodă de estimare a stării de degradare a bateriilor, bazată pe rețele neuronale de tip GRU. Capitolul 6 descrie sistemul cadru de analiză a performanțelor metodelor de estimare a stării de degradare a bateriilor. În capitolul 7 sunt prezentate rezultatele evaluării performanțelor metodelor de estimare propuse, pentru un set extins de scenarii. Capitolul 8 conține concluziile și perspectivele de cercetare și dezvoltare.

Lucrarea se încheie cu referințele bibliografice, respectiv lista de publicații ce au reieșit din cercetarea curentă precum și principalele anexe.

2. Noțiuni teoretice

În cadrul acestui capitol am prezentat cele mai importante noțiuni teoretice legate de descrierea și structura unui sistem de management al bateriilor, definirea stării de degradare a bateriilor, modele de baterii și câteva noțiuni despre rețele neuronale folosite în estimarea seriilor de timp.

3. Stadiul actual al cercetării

În literatură există o preocupare intensivă în ceea ce privește metodele de estimare a stării de degradare a bateriilor reîncărcabile [1]-[3]. Printre modalitățile de clasificare a metodelor cele mai întâlnite sunt: clasificare după complexitate, clasificare după parametrul după care se face estimarea stării de degradare; clasificare după tipul metodei de estimare.

După complexitate, metodele de estimare se împart în:

- Metode simple – în care o singură metodă de estimare este folosită
- Metode compuse - în care estimarea se face de obicei folosind o fuziune de două metode simple.

După parametrul utilizat în estimarea stării de degradare a bateriilor există următoarele tipuri de metode:

- metode în care estimarea se face pe baza capacitații bateriei
- metode în care estimarea se face pe baza rezistenței interne a bateriei
- metode în care estimare se face atât pe baza capacitații bateriei cât și pe baza rezistenței interne a bateriei.

În funcție de tipul metodei avem următoarea clasificare:

- metode bazate pe date în timp real (data driven)
- metode bazate pe filtre stocastice
- metode bazate învățare automată.

Printe alte criterii de clasificare a metodelor de estimare se numără: tipul bateriei, complexitate computațională, timpul de estimare.

În continuare voi enumera principalele metode de estimare a stării de degradare a bateriei.

Coulomb counting este una din cele mai cunoscute metode estimare [4]-[5]. această metodă constă în determinarea capacitații bateriei prin integrarea în timp curentului de încărcare/descărcare. Estimarea stării de sănătate se face de obicei prin metode de regresie [4].

Metoda OCV [6] se bazează pe determinarea unei relații între curbele de tensiune în gol și starea de sănătate a bateriei. Pentru determinarea acestei dependențe se folosesc teste extensive offline în laboratoare specializate.

În [7] se folosește o metodă bazată pe logică fuzzy. Aceasta se regăsește în general în combinație cu metode de spectroscopie a impedanței bateriei(impendance spectroscopy). Pentru aplicarea acestia este nevoie de seturi de date legate de rezistență internă a bateriei, obținute prin echipamente speciale de laborator.

Metodele de filtrare stocastică, prin intermediul filtrelor Kalman [8]-[10] sau a filtrelor de particule [11]-[12] se bazează pe modele parametrice ale bateriei. Aceste modele pot fi electrice, electrochimice, matematice. Parametrii acestor modele sunt estimate prin intermediul filtrelor.

Metodele de învățare automată SVM/RVM [13]-[14] și rețele neuronale [5]- [16] sunt metode care necesită antrenare offline pe seturi de date în vederea estimării stării de degradare a bateriei. Cu cât numărul de seturi de date folosite la antrenarea algoritmilor este mai mare, cu atât estimarea rezultată este mai bună.

O nouă metodă de estimare a stării de degradare a bateriei este prezentată în [17]. Aceasta constă în determinarea unei relații dintre curbele DV/DQ și starea de degradare a bateriei. Determinarea punctelor de inflexiune a acestor curbe denotă punctele în care bateria a atinge o schimbare considerabilă al nivelului de degradare.

Alte metode de estimare ce merită a fi menționate: [18] - folosesc câmpul magnetic pentru a caracteriza starea de degradare a bateriilor; [19]-[20], folosesc metode probabilistice și statistice pentru detecția și predicția stării de degradare a bateriilor.

4. Metoda de estimare a stării de degradare a bateriilor bazată pe regresie polinomială

Această metodă este de tip online și se bazează pe regresia liniară de ordin 2, după cum urmează: regresia polinomială încearcă să determine cu acuratețe funcția capacitații C dată prin punctele C_k corespunzătoare fiecărui ciclu k de încărcare / descărcare. Regresia polinomială are următoarea formă:

$$C_k = ak^2 + bk + c, a < 0$$

Dacă luăm în considerare valorile capacităților a n cicli de încărcare / descărcare, se pot obține valorile parametrilor funcției prin rezolvarea sistemului de ecuații:

$$\begin{cases} a \sum_k k^2 + b \sum_k k + cn = \sum_k C_k \\ a \sum_k k^3 + b \sum_k k^2 + c \sum_k k = \sum_k k C_k \quad .k = \overline{1, n}, n \geq 3 \\ a \sum_k k^4 + b \sum_k k^3 + c \sum_k k^2 = \sum_k k^2 C_k \end{cases}$$

Acest sistem se poate rezolva prin intermediul determinantelor:

$$\Delta = \begin{vmatrix} \sum_k k^2 & \sum_k k & n \\ \sum_k k^3 & \sum_k k^2 & \sum_k k \\ \sum_k k^4 & \sum_k k^3 & \sum_k k^2 \end{vmatrix} \quad \Delta_a = \begin{vmatrix} \sum_k C_k & \sum_k k & n \\ \sum_k k C_k & \sum_k k^2 & \sum_k k \\ \sum_k k^2 C_k & \sum_k k^3 & \sum_k k^2 \end{vmatrix}$$

$$\Delta_b = \begin{vmatrix} \sum_k k^2 & \sum_k C_k & n \\ \sum_k k^3 & \sum_k k C_k & \sum_k k \\ \sum_k k^4 & \sum_k k^2 C_k & \sum_k k^2 \end{vmatrix} \quad \Delta_c = \begin{vmatrix} \sum_k k^2 & \sum_k k & \sum_k C_k \\ \sum_k k^3 & \sum_k k^2 & \sum_k k C_k \\ \sum_k k^4 & \sum_k k^3 & \sum_k k^2 C_k \end{vmatrix}$$

După calcularea valorilor determinantelor se pot obține ușor valorile parametrilor ce determină funcția polinomială aplicând relațiile:

$$a = \frac{\Delta_a}{\Delta}, \quad b = \frac{\Delta_b}{\Delta}, \quad c = \frac{\Delta_c}{\Delta}.$$

Pentru calcularea mai simplă a determinantelor se pot folosi formulele recurente care asigură simplificarea computațională, respectiv fac posibilă implementarea pe o platformă de sistem încorporat cu putere de procesare și memorie redusă:

$$S_{k+1} = S_k + (k+1), \quad S_{(k+1)^2} = S_{k^2} + (k+1)^2, \text{ etc.}$$

Cu ajutorul funcției polinomiale obținute putem calcula primul ciclu m , de încărcare / descărcare pentru care capacitatea bateriei este sub un anumit nivel, $F \cdot C_{nominal}$ pentru care SoH este considerat 0%.

Calculul valorii m se reduce la rezolvarea inecuației:

$$F \cdot C_{nominal} > ak^2 + bk + c$$

Cum $a < 0$, m devine:

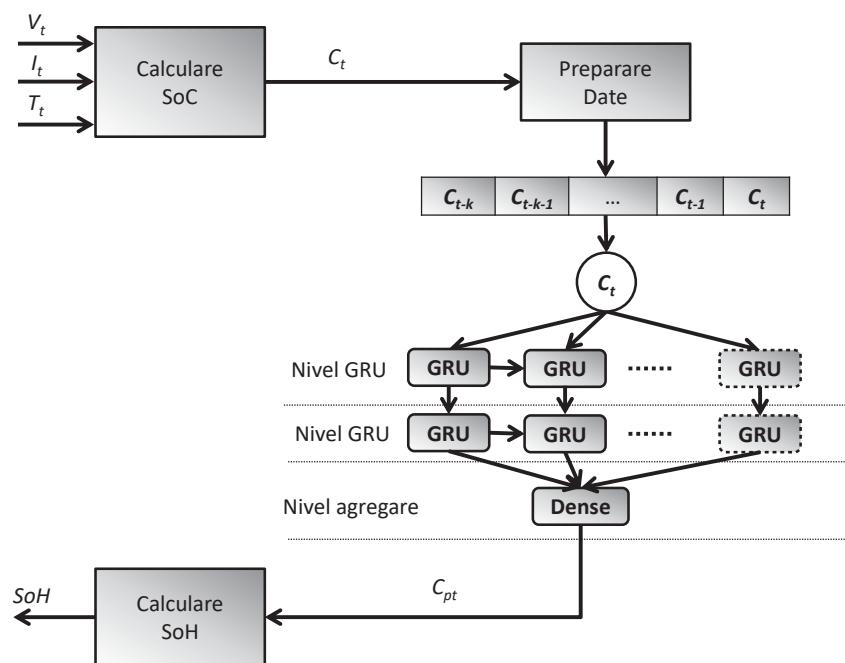
$$m = \left\lfloor \frac{-b - \sqrt{b^2 - 4ac}}{2a} \right\rfloor,$$

în care $\lfloor x \rfloor$ este partea întreagă a lui x .

Metoda regresiei polinomiale prezintă o acuratețe mare în cazul în care valorile capacității bateriei urmează un trend liniar. În cazul în care apar nelinearități, acuratețea începe să fie afectată în sens negativ.

5. Metodă de estimare a stării de degradare a bateriilor bazată pe rețelele neuronale de tip GRU

În figura următoare se prezintă structura unui sistem de management al bateriilor tipic ce folosește o metodă de estimare a stării de degradare în timp real (online).



Schema de principiu a metodei de estimare a stării de degradare a bateriilor bazată pe rețelele neuronale de tip GRU

Acest sistem este compus din mai multe subcomponente:

- Blocul ce asigură determinarea SoC – acest bloc asigură calcularea în timp real a parametrului de ieșire (în cazul nostru capacitatea bateriei la momentul t), C_t în funcție de parametrii de intrare, care în exemplul de față sunt tensiunea la borne, curentul de descărcare și temperatura bateriei, reprezentate prin V_t, I_t, T_t .
- Blocul „Preparare date” – asigură pregătirea datelor și ajustarea acestora pentru prezentarea acestora la intrarea rețelei neuronale recurente.

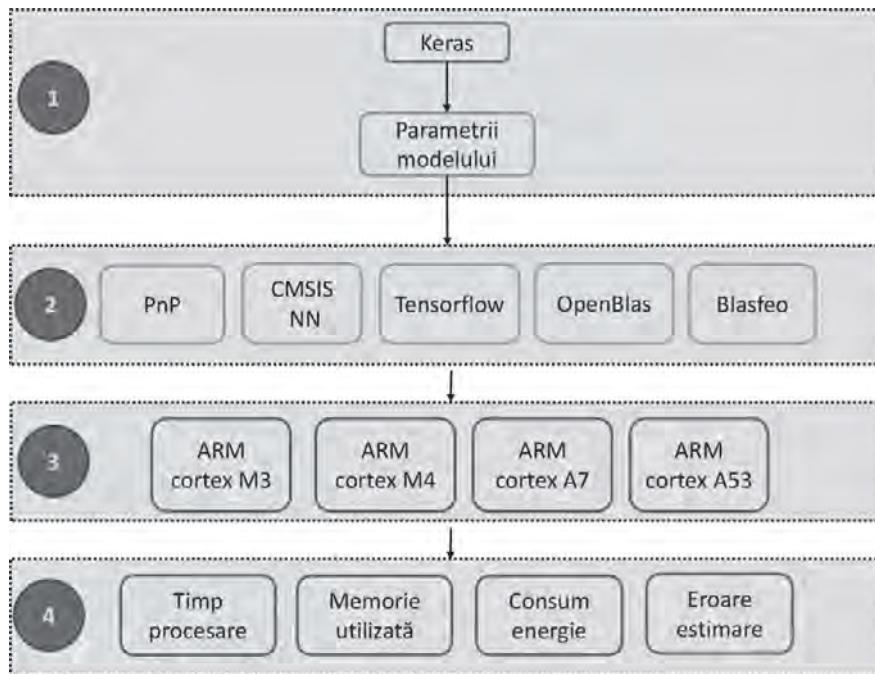
- Rețeaua neuronală propriu-zisă.
- Blocul de calculare SoH se ocupă de transformarea capacitații estimate a bateriei și calcularea procentuală a stării de degradare a bateriei conform relației

$$SOH [\%] = \begin{cases} 100\%, & \frac{C_{bat}}{C_{nom}} > 1 \\ \left(1 - \frac{C_{bat}}{C_{nom}} \right) \cdot 100 [\%], & 0\% < \frac{C_{bat}}{C_{nom}} \leq 1 \\ 0\%, & \frac{C_{bat}}{C_{nom}} < SOH_0 \end{cases} \quad (56)$$

6. Sistem cadru de evaluare a performanțelor metodelor de estimare a stării de degradare a bateriilor bazate pe rețele neuronale

Structura sistemului de analiză a performanțelor este una pe nivele și este cuprinsă în figura de mai jos:

- Nivelul 1 – este nivelul de reprezentare a modelului. Pentru simplitate am ales Keras ca mediu de modelare cu ajutorul limbajului de programare Python.
- Nivelul 2 – este nivelul de reprezentare computațional pe platforme de sisteme incorporate. Se pot alege pentru comparare mai multe biblioteci de procesare cum ar fi: PnP (Paper and Pencil), Tensorflow etc.
- Nivelul 3 – este nivelul de platformei HW pe care se dorește implementarea.
- Nivelul 4 – este nivelul de colectare a metricilor de evaluare a performanței metodei de evaluare a stării de degradare a bateriilor în implementare reală.



Structura sistemului cadrul de evaluare a performanțelor metodelor de estimare a stării de degradare a bateriilor

Criteriile de evaluare și metricile de performanță fac parte din nivelul 4 al sistemului cadrui descris în acest capitol:

- Timpul de procesare – este timpul definit în ms pentru calcularea estimării stării de degradare a bateriilor la fiecare ciclu de descărcare. Acest timp depinde de frecvența procesorului și numărul de nuclee pe care rulează algoritmul.
- Memoria utilizată – în funcție de platformă aleasă avem mai multe tipuri de memorie: flash (pentru constante), SRAM și DRAM pentru algoritm propriu zis.
- Consumul de energie – este consumul de energie utilizat pentru estimarea stării de degradare la finalul fiecărui ciclu de descărcare a bateriei. Este raportat în mAh.
- Eroarea de estimare este eroare relativă procentuală rezultată în urma aplicării setului de date de test. Aceasta se poate compara cu eroarea obținută în urma rulării simulării pe calculator pentru a observa dacă există vreo diferență datorită implementării pe sistem incorporat.

7. Evaluarea performanțelor

Metodele bazate pe rețelele neuronale prezintă cea mai mare acuratețe conform [3]. Eroarea acestor metode se situează în jurul valorii de 1% – 1.5%. Aceste valori au fost obținute în marea majoritate a lor prin folosirea unor seturi de date rezultate din ciclarea bateriilor la temperatura ambientă de 25 de grade Celsius, încărcarea și descărcarea făcându-se cu un curent constant. Acum l-am confirmat prin rularea scenariului experimental 25-DEG-CC-SF.

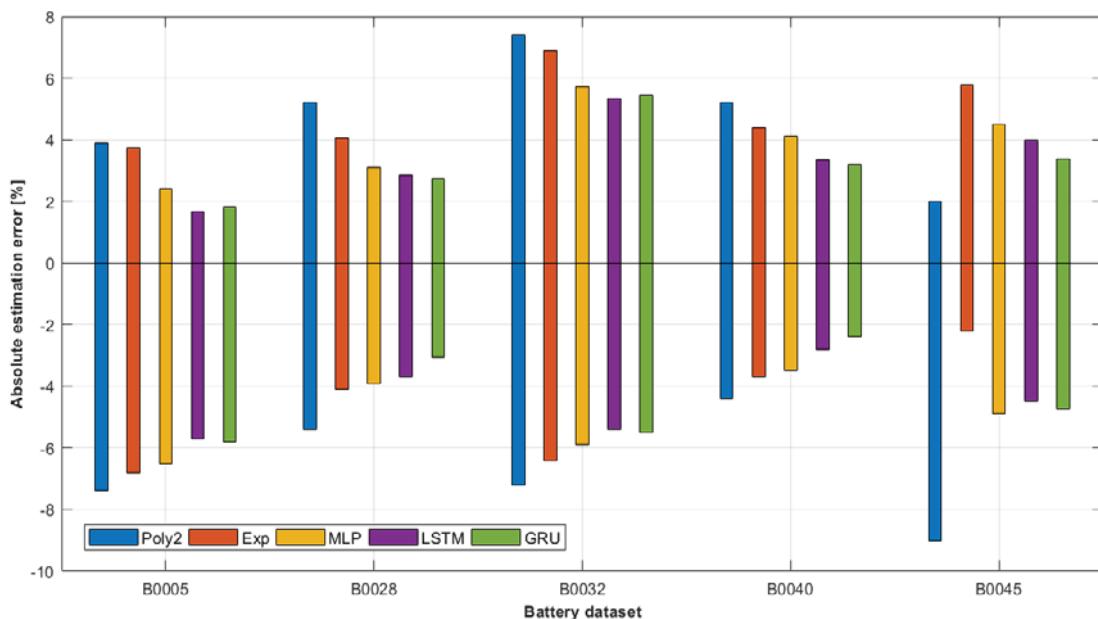
Totuși prin utilizarea unui set de date ce conține scenarii mai aproape de utilizare reală, cu curenti de descărcare variabili și multiple valori pentru temperatura de operare, am obținut un interval de eroare ce se apropie de valoarea mediană a erorii de estimare a celor mai des întâlnite metode de estimare.

Comparativ cu alte metode bazate pe rețele neuronale cu memorie [21] cum ar fi LSTM, metoda bazată pe celule GRU are avantajul că prezintă o structură mai simplă a celulei și de aceea numărul parametrilor modelului de estimare este cu 25% mai redus decât cel al LSTM. Acest lucru este important atât pentru procesul de învățare cât și la implementarea metodei în cadrul unui sistem încorporat cu resurse computaționale reduse.

Tabelul de mai jos sumarizează comparația modelului GRU cu LSTM

Criteriu	LSTM	GRU
Nr. de parametri model	30651	23001
Eroare medie absolută învățare	0.270	0.264
Interval eroare relativă procentuală pt. ALL-DEG-CC	[-5.02, 5.24]	[-5.13, 5.32]

Tot în [21] am folosit un set de date asemănător cu ALL_DEG_CC, în care am considerat limita bateriei degradate între 60% și 70%. Folosind acest set de date am comparat GRU cu cele mai cunoscute metode bazate pe rețele neuronale, precum și metodele bazate pe regresie în sensul celor mai mici pătrate. Rezultatele sunt sumarizate în figura de mai jos, pentru diferite baterii selectate.



Studiu comparativ a principalelor metode de estimare cu implementare pe sisteme încorporate [21].

Metodele bazate pe regresie polinomială și exponențială prezintă erori de estimare bune în cazul în care curba capacității urmărește graficul unei funcții polinomiale sau exponențiale. În majoritatea cazurilor, neliniaritățile caracteristice capacității bateriei fac ca eroarea de estimare să crească, de exemplu la un interval de eroare [-7.5%, 4%] respectiv [-7%, 3.8%]

pentru bateria B0005. Metodele bazate pe rețele neuronale prezintă o acuratețe de estimare mult mai bună: începând cu MLP, pentru care eroarea de estimare este între -6.5% și 2.5% și continuând cu LSTM și GRU pentru care eroare se situează în intervalul [-5.5%, 2%] pentru bateria B0005, aproape la jumătate ca primele metode amintite. Îmbunătățirea erorii de estimare se datorează structurii celulei rețelelor neuronale recurente LSTM și GRU care folosesc memorie pe termen lung, respectiv pe termen scurt.

Când capacitatea bateriei prezintă multiple puncte de regenerare, acuratețea de estimare scade și pentru LSTM și GRU, iar diferența dintre metode nu mai e aşa de seminificativă. Acest lucru se poate observa la bateria B0032. Chiar și aşa, eroarea de estimare se află într-un interval acceptabil.

8. Concluzii și perspective

Teza de față prezintă activitatea de cercetare și dezvoltare efectuată în cadrul programului de cercetare doctorală "Evaluarea stării de degradare a bateriilor reîncărcabile în sisteme alimentate cu baterii" realizată de către mine sub conducerea științifică a domnului prof. dr. ing. Mihai V. Micea.

Primul obiectiv a fost atins prin implementarea metodei de estimare a stării de degradare a bateriilor reîncărcabile descrise la capitolul 5, bazate pe rețele neuronale cu celule GRU. În plus am definit și o optimizare a acestei metode pentru tipuri de baterii ce prezintă efectul de regenerare a capacitații. De menționat este faptul că metoda descrisă la capitolul 5 este o îmbunătățire a metodei implementate tot de mine și a cărei specific este descris la capitolul 4, metoda bazată pe regresie polinomială. Metoda descrisă la capitolul 5 se poate implementa pe sisteme incorporate de la cele mai simple ajungând la cele mai complexe în funcție de platformă software aleasă.

Cel de-al doilea obiectiv a fost atins prin descrierea și implementarea cadrului de evaluare a performanței metodelor de estimare a stării de degradare a bateriilor de la capitolul 5. Acest sistem cadru de evaluare a performanței a fost dezvoltat având ca scop obținerea unor metriki prin care să se poate analiza și categorisi orice metodă de estimare a stării de degradare a bateriilor, cu precădere cele bazate pe rețele neuronale. De asemenea în cadrul metodei descrise la capitolul 4 am implementat atât hardware cât și software un BMS complet.

Din lucrarea de față se pot evidenția mai multe direcții de dezvoltare ulterioare. Acestea se pot grupa în funcție de obiectivele prezentei teze. În ceea ce privește metode de estimare a stării de degradare a bateriilor se pot distinge o serie de îmbunătățiri:

- Transformarea modelului într-un model dinamic de actualizare a parametrilor – rețeaua neuronală prezentată are parametri fișă calculați pe baza datelor din cadrul procesului de antrenare. Datorită specificului metodei de a rula în timp real este benefic ca acești parametri să poată fi actualizați cu fiecare ciclu de baterie introdus prin utilizarea într-un sistem de management al bateriei.
- Folosirea metodei prezentate împreună cu alte metode mai simple sau complexe în vederea obținerii unui model mai performant.

Înținând cont de cel de-al doilea obiectiv, direcțiile de dezvoltare ulterioară pot fi:

- Lărgirea plajei de sisteme incorporate pe care se poate face evaluarea.
- Adăugarea de suport pentru mai multe biblioteci software de procesare precum și platformelor software
- Definirea unui scor prin intermediul căruia să poată fi comparate metodele.

Referințe

- [1] W. Waag, C. Fleischer, D.U. Sauer, "Critical Review of the Methods for Monitoring of Lithium-Ion Batteries in Electric and Hybrid Vehicles", *J. Power Sources*, 258, 2014, (321–339).
- [2] X.S. Si, W. Wang, C.H. Hu, D.H. Zhou, "Remaining Useful Life Estimation: A Review on the Statistical Data Driven Approaches", *J. Power Sources*, 213, 2011, (1–14).
- [3] 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," *Renewable & Sustainable Energy Reviews*, vol. 56, pp. 572-587, Apr 2016
- [4] M.V. Micea, L. Ungurean, G.N. Carstoiu, V. Groza, "Online State-of-Health Assessment for Battery Management Systems", *IEEE Trans. Instrum. Meas.*, 60 (6), 2011, (1997–2006).
- [5] K.S. Ng, C.S. Moo, Y.P. Chen, Y.C. Hsieh, "Enhanced Coulomb Counting Method for Estimating State-of-Charge and State-of-Health of Lithium-Ion Batteries", *Applied Energ.*, 86, 2009, (1506–1511).
- [6] C. Weng, J. Sun, H. Peng, "A Unified Open-Circuit-Voltage Model of Lithium-Ion Batteries for State-of-Charge Estimation and State-of-Health Monitoring", *J. Power Sources*, 258, 2014, (228–237).
- [7] H.T. Lin, T.J. Liang, S.M. Chen, "The State-of-Health Diagnosis of Li-Co Batteries with Fuzzy Identification", in *Proc. IEEE PEMCC*, 2012, (2678–2682).
- [8] A. Saxena, " Subject MI63: Kalman Filter Tank Filling", *Cornell Univ.*, 2008, Online: <http://www.cs.cornell.edu/courses/cs4758/2012sp/materials/mi63slides.pdf>.
- [9] B. Rosca, J.T.B.A. Kessels, H.J. Bergveld, P.P.J. van den Bosch, "On-line Parameter, State-of-Charge and Aging Estimation of Li-ion Batteries", in *Proc. IEEE VPPC*, 2012, (1122–1127).
- [10] D. Andre, A. Nuhic, T. Soczka-Guth, D.U. Sauer, "Comparative Study of a Structured Neural Network and an Extended Kalman Filter for State of Health Determination of Lithium-Ion
- [11] S. Schwunk, N. Armbruster, S. Straub, J. Kehl, M. Vetter, "Particle Filter for State of Charge and State of Health Estimation for Lithium-Iron Phosphate Batteries", *J. Power Sources*, 239, 2013, (705–710).
- [12] Y. Xing, E.W.M. Ma, K.L. Tsui, M. Pecht, "A Case Study on Battery Life Prediction Using Particle Filtering", in *Proc. IEEE PHM*, 2012, (1–6).
- [13] A. Eddahech, O. Briat, J.M. Vinassa, "Determination of Lithium-Ion Battery State-of-Health Based on Constant-Voltage Charge Phase", *J. Power Sources*, 258, 2014, (218–227)
- [14] D. Wang, Q. Miao, M. Pecht, "Prognostics of Lithium-Ion Batteries Based on Relevance Vectors and a Conditional Three-Parameter Capacity Degradation Model", *J. Power Sources*, 239, 2013, (253-264).
- [15] A. Eddahech, O. Briat, N. Bertrand, J.Y. Deletage, J.M. Vinassa, "Behavior and State-of-Health Monitoring of Li-Ion Batteries Using Impedance Spectroscopy and Recurrent Neural Networks", *Electr. Power Energ. Syst.*, 42, 2012, (487–494).
- [16] H.T. Lin, T.J. Liang, S.M. Chen, "Estimation of Battery State of Health Using Probabilistic Neural Network", *IEEE Trans. Ind. Informatics*, 9 (2), 2013, (679–685).
- [17] L. Wang, C. Pan, L. Liu, Y. Cheng, X. Zhao, "On-board state of health estimation of LiFePO₄ battery pack through differential voltage analysis", *Applied Energy* 168, 2016, 465-472.
- [18] N. Khare, P. Singh, J.K. Vassiliou, "A Novel Magnetic Field Probing Technique for Determining State of Health of Sealed Lead-Acid Batteries", *J. Power Sources*, 218, 2012, (462-473).
- [19] G. Jin, D.E. Matthews, Z. Zhou, "A Bayesian Framework for On-Line Degradation Assessment and Residual Life Prediction of Secondary Batteries in Spacecraft", *Reliab. Eng. Syst. Safety*, 113, 2013, (7–20).
- [20] S.S.Y. Ng, Y. Xing, K.L. Tsui, "A Naive Bayes Model for Robust Remaining Useful Life Prediction of Lithium-Ion Battery", *Applied Energ.*, 118, 2014, (114-123).
- [21] L. Ungurean, M. V. Micea, and G. Cârstoiu, 'Online state of health prediction method for lithium-ion batteries, based on gated recurrent unit neural networks', *International Journal of Energy Research*, vol. 44, no. 8, pp. 6767–6777, Apr. 2020, doi: 10.1002/er.5413.