

Evaluarea stării de degradare a bateriilor reîncărcabile în sisteme alimentate cu baterii

Teză destinată obținerii
titlului științific de doctor inginer
la
Universitatea Politehnica Timișoara
în domeniul CALCULATOARE ȘI TEHNOLOGIA
INFORMAȚIEI
de către

Ing. Lucian UNGUREAN

Președintele comisiei:	prof.univ.dr.ing Mircea Stratulat
Conducător științific:	prof.univ.dr.habil. ing. Mihai V. Micea
Referenți științifici:	prof.univ.dr. Marius Marcu ș.l. dr.ing. Sebastian Fuicu

Ziua susținerii tezei:

Seriile Teze de doctorat ale UPT sunt:

- | | |
|---|---|
| 1. Automatică | 11. Știința și Ingineria Materialelor |
| 2. Chimie | 12. Ingineria Sistemelor |
| 3. Energetică | 13. Inginerie Energetică |
| 4. Inginerie Chimică | 14. Calculatoare și Tehnologia Informației |
| 5. Inginerie Civilă | 15. Ingineria Materialelor |
| 6. Inginerie Electrică | 16. Inginerie și Management |
| 7. Inginerie Electronică și Telecomunicații | 17. Arhitectură |
| 8. Inginerie Industrială | 18. Inginerie Civilă și Instalații |
| 9. Inginerie mecanică | 19. Inginerie Electronică, Telecomunicații și Tehnologii Informaționale |
| 10. Știința Calculatoarelor | |

Universitatea Politehnica Timișoara a inițiat seriile de mai sus în scopul diseminării expertizei, cunoștințelor și rezultatelor cercetărilor întreprinse în cadrul Școlii doctorale a universității. Seriile conțin, potrivit H.B.Ex.S Nr. 14 / 14.07.2006, tezele de doctorat susținute în universitate începând cu 1 octombrie 2006.

Copyright © Editura Politehnica – Timișoara, 2021

Această publicație este supusă prevederilor legii dreptului de autor. Multiplicarea acestei publicații, în mod integral sau în parte, traducerea, tipărirea, reutilizarea ilustrațiilor, expunerea, radiodifuzarea, reproducerea pe microfilme sau în orice altă formă este permisă numai cu respectarea prevederilor Legii române a dreptului de autor în vigoare și permisiunea pentru utilizare obținută în scris din partea Universității Politehnica Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300223 Timișoara, Bd. Vasile Pârvan 2B
Tel./fax 0256 404677
e-mail: editura@upt.ro

Cuvânt înainte

Această lucrare este rezultatul unui proces îndelungat, uneori anevoios al activității de cercetare ce am desfășurat-o în cadrul DSPLabs din cadrul universității Politehnica din Timișoara.

Țin să mulțumesc în mod deosebit conducătorului meu de doctorat, prof. dr. habil. Ing. Mihai V. Micea care m-a îndrumat și susținut pe tot parcursul activității doctorale și fără de care nu aș fi luat hotărârea de a începe studiile doctorale.

Doresc să îmi exprim recunoștința și față de prof. dr. ing. Mircea Stratulat, prof. dr. ing. Marius Marcu și ș.l. dr. ing. Sebastian Fuicu pentru îndrumarea și ajutorul oferit în acești ani în cadrul comisiei de îndrumare doctorală.

Mulțumesc întregului colectiv DSPLabs pentru sprijinul acordat, prietenilor și colegilor mei ing. Gabriel Cârstoiu, ș.l. Cristina Stângaciu, ș.l. Valentin Stângaciu, ș.l. Răzvan Cioargă, ing. Ramona Cioargă. De asemenea doresc să mulțumesc ing. Dan Chiciudean pentru inițierea în lumea vastă a sistemelor încorporate.

Nu în ultimul rând doresc să mulțumesc soției mele Olivia pentru suportul și înțelegerea acordată în tot acest timp, copiilor mei, părinților care m-au susținut pe tot parcursul formării educaționale.

Familiei mele.

UNGUREAN, Lucian

Evaluarea stării de degradare a bateriilor reîncărcabile în sisteme alimentate cu baterii

Teze de doctorat ale UPT, Seria X, Nr. YY, Editura Politehnica, 2021, 100 pagini, 48 figuri, 9 tabele.

ISSN:

ISBN:

Cuvinte cheie

Starea de degradare a bateriilor, sisteme de management al bateriilor, rețele neuronale recurente.

Rezumat

Datorită avansului tehnologic numărul sistemelor alimentate cu baterii a suferit 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.

Lucrarea de față abordează problema estimării stării de degradare a bateriilor reîncărcabile. Unul din obiectivele importante al acesteia este prezentarea detaliată a multitudinii de metode de estimare existente, prezentând avantajele și dezavantajele fiecăreia dintre ele în funcție de un set bine definit de criterii mergând de la chimia bateriei până la eroare de estimare și complexitatea computațională.

Dezvoltarea domeniului de inteligență artificială în tandem cu îmbunătățirile din domeniul hardware al procesoarelor a făcut ca implementarea rețelelor neuronale să fie posibilă pe sisteme încorporate.

Unul din cele mai importante obiective ale acestei teze este definirea unei metode noi de estimare a stării de degradare a bateriilor bazate pe rețele neuronale de tip GRU. Evaluarea performanțelor metodei implementată pe PC într-un mediu de simulare este detaliată în comparație cu implementările reale pe diferite sisteme încorporate.

Nu în ultimul rând, un alt obiectiv important este definirea unui sistem cadru pentru evaluarea performanțelor metodelor de estimare a stării de degradare a bateriilor pe sisteme încorporate, în termeni de complexitate computațională, consum de energie și eroare de estimare. Utilitatea acestui sistem cadru este compararea metodelor existente precum și sprijinirea dezvoltării unor metode noi de estimare.

CUPRINS

Listă de acronime	7
Listă tabele	8
Lista de figuri	9
1. Introducere	11
1.1 Domeniile și tema cercetării.....	11
1.2 Motivația cercetării	11
1.3 Obiective propuse.....	12
1.4 Structura lucrării	12
2. Noțiuni teoretice	13
2.1 Sisteme de management al bateriilor.....	13
2.2 Starea de degradare a bateriilor	14
2.3 Modelarea bateriilor	15
2.3.1 Modelul electric	15
2.3.2 Modelul electrochimic.....	16
2.3.3 Modelul matematic	16
2.3.4 Modelul bazat pe ciclul de viață a bateriei	17
2.4 Rețele neuronale pentru estimarea seriilor de timp	18
2.4.1 Taxonomia problemelor legate de estimarea seriilor de timp	19
2.4.2 Rețele neuronale de tip MLP.....	19
2.4.3 Rețele neuronale de tip LSTM.....	20
2.4.4 Rețele neuronale de tip GRU	25
3. Abordări curente privind metodele pentru evaluarea stării de degradare a bateriilor	29
3.1 Discuție asupra metodelor existente de estimare a stării de degradare a bateriilor.....	29
3.1.1 Coulomb Counting	30
3.1.2 OCV.....	31
3.1.3 Spectroscopia de impedanță	32
3.1.4 Filtre Kalman	34
3.1.5 Logică Fuzzy	37
3.1.6 Vectori suport	38
3.1.7 Filtre particule.....	40
3.1.8 Alte metode	43
3.2 Evaluarea comparativă a metodelor existente de estimare a SOH/RUL	46
3.3 Concluzii	52
4. Metodă de evaluare a stării de degradare a bateriilor bazată pe regresie polinomială	55
4.1 Descrierea metodei.....	55
4.2 Implementarea metodei	57
5. Metodă de evaluare a stării de degradare a bateriilor folosind rețele neuronale recurente de tip GRU	61
5.1 Descrierea metodei.....	61
5.2 Structura rețelei neuronale.....	63
5.3 Antrenarea rețelei	64
5.4 Variantă modificată prin adăugarea unui filtru treaptă.....	65
6. Sistem cadru de analiză a performanțelor metodelor de estimare a stării de degradare a bateriilor bazate pe rețele neuronale	67
6.1 Obiective.....	67
6.2 Structura sistemului	67

6.3 Criterii de evaluare și metrici de performanță.....	68
6.4 Exemplu de evaluare a performanței folosind implementarea PnP.....	69
7. Evaluarea performanțelor.....	73
7.1 Criterii de evaluare	73
7.2 Configurarea metodei	73
7.3 Rezultatele evaluării metodei pe setul de date NASA PCOE	73
7.3.1 Evaluarea performanțelor pentru scenariul 25-DEG-CC.....	74
7.3.2 Evaluarea performanțelor pentru scenariul ALL-DEG-CC	75
7.3.3 Evaluarea performanțelor pentru scenariul 25-DEG-CC-RW.....	75
7.3.4 Evaluarea performanțelor pentru scenariul ALL-DEG-CC-RW	76
7.3.5 Evaluarea performanțelor pentru scenariul 25-DEG-CC-SF.....	77
7.3.6 Evaluarea performanțelor pentru scenariul ALL-DEG-CC-SF	77
7.3.7 Evaluarea performanțelor pentru scenariul 25-DEG-CC-RW-SF	78
7.3.8 Evaluarea performanțelor pentru scenariul ALL-DEG-CC-RW-SF	78
7.3.9 Analiza repetabilității pentru scenariul ALL-DEG-CC-RW-SF	79
7.3.10 Analiza overfit/underfit pentru scenariul ALL-DEG-CC-RW-SF	79
7.3.11 Analiza structurii rețelei neuronale folosind scenariul ALL-DEG-CC-RW-SF..	80
7.3.12 Analiza crossvalidare folosind scenariul ALL-DEG-CC-RW-SF.....	80
7.4 Discutarea rezultatelor și studiul comparativ cu alte metode	83
8. Concluzii și perspective	87
8.1 Concluzii	87
8.2 Rezumat al contribuțiilor	88
8.3 Perspective de cercetare și dezvoltare.....	88
Referințe bibliografice.....	89
Publicații.....	96
Anexa 1. Descrierea setului de date NASA Prognostics center of excellence	97

LISTĂ ACRONIME

ARMA (autoregressive moving average)	37
BMS (Battery management system)	13
DC (direct current)	13
DoD (depth of discharge)	11
EEPROM (electrically erasable programmable read-only memory)	14
EIS (electronic impedance spectroscopy)	32
EKF (extended Kalman Filter)	37
FFNN (feed forward neural network)	19
GRU (Gated recurrent unit)	12
I2C (inter integrated circuit)	14
LCD (liquid crystal display)	14
LED (light emitting diode)	14
LSTM (long short term memory)	20
MLP (multilayer perceptron)	19
OCV (open circuit voltage)	15
PnP (Paper and Pencil)	67
RMSE (root mean square error)	31
RNN (recurrent neural network)	33
RS-232 (recommended standard 232)	14
RUL (remaining useful life)	14
RVM (relevance vector machines)	39
SOC (state of charge)	31
SoH (State of health)	11
SPI (serial peripheral interface)	14
SVR (support vector regression)	36

LISTĂ TABELE

Tabel 1. Operatori de logica fuzzy	37
Tabel 2. Evaluarea metodelor de estimare a stării de degradare a bateriilor	47
Tabel 3. Configurarea metodei de estimare bazată pe rețele neuronale de tip GRU	73
Tabel 4. Caracteristici de antrenare a rețelei	73
Tabel 5. Analiza structurii rețelei neuronale	80
Tabel 6. Valoarea parametrului de corelație pentru pașii de crossvalidare	81
Tabel 7. Lista platformelor HW și configurarea SW pentru evaluarea implementării metodei pe sisteme încorporate	82
Tabel 8. Evaluarea implementării metodelor pe sisteme încorporate	83
Tabel 9. Comparație între rețele neuronale LSTM și GRU [3]	85

LISTĂ FIGURI

Fig. 1. Structura generală a unui BMS [2]	13
Fig. 2. Modelul Randles [4]	15
Fig. 3. Modelul Electrochimic [12]	16
Fig. 4. Arhitectura rețelei neuronale MLP [30]	19
Fig. 5. Calea de date și operațiile din cadrul rețelei neuronale MLP [30]	20
Fig. 6. Arhitectura rețelei neuronale LSTM	21
Fig. 7. Căile de date dintr-o rețea LSTM [35]	22
Fig. 8. Starea celulei LSTM [35]	22
Fig. 9. Poartă în cadrul celulei [35]	22
Fig. 10. Controlul memoriei pe termen lung [35]	23
Fig. 11. Controlul memoriei pe termen scurt [35]	24
Fig. 12. Actualizarea stării celulei LSTM [35]	25
Fig. 13. Calea de date pentru ieșire [35]	25
Fig. 14. Arhitectura rețelei neuronale GRU	26
Fig. 15. Structura internă și căile de date din cadrul celulei GRU [3]	27
Fig. 16. Clasificarea metodelor de estimare a stării de degradare a bateriilor	29
Fig. 17. Modelul electric simplificat	31
Fig. 18. Diagrama Niquist obținută prin EIS [16]	32
Fig. 19. Impedanța estimată și cea măsurată partea reală [16]	33
Fig. 20. Variante de filtre Kalman utilizare în sisteme neliniare	34
Fig. 21. Arhitectura Filtrului Kalman Dual	36
Fig. 22. Rezultatele predicției folosind filtru de particule [73]	40
Fig. 23. Transformare MPF a funcției de distribuție de probabilitate Posterioară	42
Fig. 24. Algoritm de estimare RUL propus in [87]	45
Fig. 25. Placa de management al consumului în cadrul unui WIT	58
Fig. 26. Schema de tip high-side pentru măsurarea curentului	58
Fig. 27. Arhitectura software al plăcii de management al consumului	59
Fig. 28. Schema de principiu a metodei de estimare a stării de degradare a Bateriilor bazată pe rețele neuronale de tip GRU	61
Fig. 29. Structura rețelei neuronale cu celule de tip GRU	64
Fig. 30. Efectul de regenerare întâlnit la unele tipuri de baterii	65
Fig. 31. Capacitatea bateriei B01(Panasonic NCR18650A)	66
Fig. 32. Metoda de estimare modificată prin introducerea filtrului treaptă	66
Fig. 33. Structura sistemului cadrul de evaluare a performanțelor metodelor de estimare a stării de degradare a bateriilor	68
Fig. 34. Eroare relativă procentuală pentru cele 8 scenarii de evaluare semnificative	74
Fig. 35. Distribuția erorii de estimare în cadrul scenariului 25-DEG-CC	75
Fig. 36. Distribuția erorii de estimare în cadrul scenariului ALL-DEG-CC	75
Fig. 37. Distribuția erorii de estimare în cadrul scenariului 25-DEG-CC-RW	76
Fig. 38. Distribuția erorii de estimare în cadrul scenariului ALL-DEG-CC-RW	76
Fig. 39. Distribuția erorii de estimare în cadrul scenariului 25-DEG-CC-SF	77
Fig. 40. Distribuția erorii de estimare în cadrul scenariului ALL-DEG-CC-SF	77
Fig. 41. Distribuția erorii de estimare în cadrul scenariului 25-DEG-CC-RW-SF	78
Fig. 42. Distribuția erorii de estimare în cadrul scenariului ALL-DEG-CC-RW-SF	78

Fig. 43. Analiza repetabilității pentru scenariul ALL-DEG-CC-RW-SF	79
Fig. 44. Analiza overfitt/underfitt pentru scenariul ALL-DEG-CC-RW-SF	80
Fig. 45. Parametru de corelație pentru pasul 1 de crossvalidare	81
Fig. 46. Platforme fizice folosite	82
Fig. 47. Acuratețea estimării pentru diferite metode de estimare a stării de degradare a bateriilor [105]	84
Fig. 48. Studiu comparativ a principalelor metode de estimare cu implementare pe sisteme încorporate [3]	85

1. INTRODUCERE

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 tehnologiilor 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. Motivația cercetării

În domeniul dispozitivelor încorporate alimentate cu baterii reîncărcabile, sistemele de management al bateriilor joacă un rol important, urmărind îndeplinirea următoarelor funcționalități [1]:

- Asigurarea unui mediu de operare sigur, definit de specificațiile tehnice ale bateriei și tipului acesteia, precum curentul maxim de încărcare, curentul maxim de descărcare, limitele inferioare și superioare ale nivelului DoD, nivele inferioare și superioare ale tensiunii bateriei, etc.
- Monitorizarea continuă a parametrilor bateriilor pentru determinarea și predicția stării acesteia.

Soluțiile de management al bateriilor constau de obicei într-un dispozitiv hardware pe care rulează o aplicație software de management. Algoritmii de determinare și predicție a stării de sănătate a bateriei variază de la cei mai simpli care pot să opereze pe un hardware cu resurse limitate, până la cei mai complecși care necesită resurse hardware suplimentare.

Legat de evaluarea stării de degradare a bateriei, literatura de specialitate menționează următoarele probleme de actualitate:

- Problema neliniarității și a incertitudinii de estimare: datorată modului de utilizare a bateriilor precum și natura parametrilor acesteia.

- Problema complexității algoritmilor de estimare și a resurselor limitate: datorată tipului de algoritm de estimare. Cele mai complexe metode de estimare necesită resurse hardware și putere de procesare pe care microcontrolere de uz general nu le pot oferi, acestea rămânând adeseori la nivel conceptual sau la nivel de simulare în medii precum Matlab.

Activitatea de cercetare sintetizată prin teza de față abordează cele două probleme mai sus menționate și are ca scop ameliorarea acestora prin dezvoltarea unei noi metode de estimare precum și validarea acestei metode într-un cadru complet de analiză a performanțelor bazat pe criterii atent definite.

1.3. Obiective propuse

Principalul scop al acestei teze de doctorat este găsirea unor soluții pentru îmbunătățirea sau chiar rezolvarea unor problemele 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:
 - acuratețe de estimare cât mai ridicată în ceea ce privește SoH, respectiv
 - 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:
 - criterii de precizie și acuratețe,
 - criterii de evaluare a complexității algoritmilor,
 - criterii de evaluare a resurselor de microprocesor utilizare precum și a consumului propriu de energie al algoritmului.

1.4. 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

2.1. Sisteme de management al bateriilor

Sistemele de management al bateriilor sunt componentele esențiale din cadrul sistemelor alimentate cu baterii. Principala funcție este asigurarea utilizării bateriei într-un mod cât mai eficient în vederea minimizării stării de degradare. Acest lucru se obține prin monitorizarea parametrilor bateriei în procesul de încărcare și procesul de descărcare al acesteia. De asemenea sistemele de management al bateriilor oferă informații utile despre ciclurile de încărcare/descărcare, timpul de utilizare rămas, etc.

În figura 1 este descrisă structura generală a unui sistem de management al bateriilor (BMS) [2]. Modulul de alimentare este conectat la rețea și asigură energia necesară încărcării bateriei. Acesta poate fi parte integrată pe placa sistemului sau poate fi detașabil. Convertorul DC/DC este folosit pentru a asigura nivelul de tensiune pentru funcționarea consumatorului. Acesta translatează nivelul de tensiune al bateriei la nivelul de tensiune dorit. Bateria este încărcată de la modulul de alimentare. Aceasta este prevăzută cu circuitele de protecție pentru asigurarea unui anumit grad de siguranță. Modulul de monitorizare a stării bateriei are rol de achiziție/determinare a parametrilor bateriei

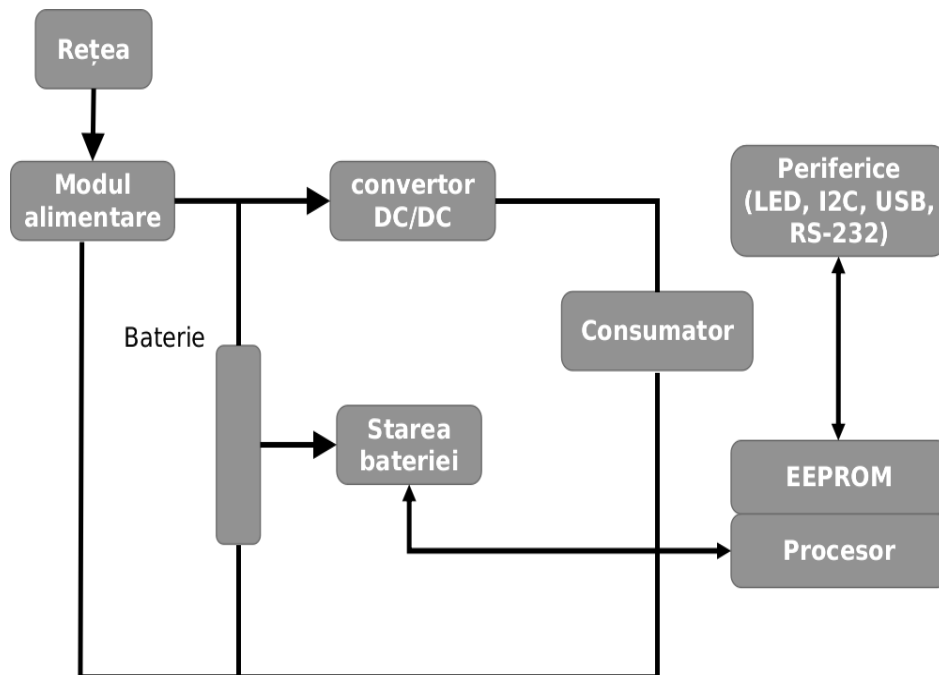


Fig. 1. Structura generală a unui BMS [2]

În cadrul sistemului BMS, sunt monitorizați activ parametri precum tensiunea bateriei, curentul de încărcare/descărcare, temperatura bateriei, etc. Pe

baza acestora se pot determina alți parametri precum capacitatea, rezistența internă, starea de degradare (SoH), numărul de cicluri rămași până bateria este considerată neutilizabilă (RUL).

Modulul de comunicare este format dintr-un procesor/micro controller folosit pentru a salva datele în memoria EEPROM și pentru a transmite mai departe informațiile printr-una dintre interfețele de comunicație (I2C, RS-232, SPI, etc.) sau afișarea stării bateriei printr-un indicator LED sau chiar informații pe un afișaj LCD. Consumatorul transformă energia electrică în energia corespunzătoare destinației acestuia: energie mecanică, sunet, lumină, etc.

2.2. Starea de degradare a bateriilor

Starea de degradare a bateriilor se poate reprezenta prin diferite metrice, cele mai importante sunt următoarele: starea de degradare (SoH) și timpul util de operare rămas (RUL).

Starea de degradare (SoH) este o metrică raportată la starea inițială a bateriei. În momentul producerii bateriei, SoH este considerat 100 % – corelat cu valoarea maximă a energiei pe care bateria poate să o furnizeze. Utilizând bateria, apar fenomenele fizice și chimice ireversibile care duc la scăderea energiei pe care bateria poate să o furnizeze. Când energia furnizată scade sub un anumit nivel, bateria este considerată degradată și trebuie schimbată. În acest moment SoH este considerat 0%.

O definiție simplificată a SoH pe care am folosit-o în această lucrare se bazează pe capacitatea bateriei [3]:

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

în care C_{bat} reprezintă capacitatea curentă a bateriei, C_{nom} – capacitatea nominală a bateriei, SOH_0 – raportul dintre capacitatea bateriei și capacitatea nominală pentru care bateria este considerată degradată. În mod uzual, SOH_0 are valoarea 0,2 sau 0,3.

În ceea ce privește timpul util de operare rămas (RUL) este strâns legat de SoH și se definește prin numărul de cicluri de încărcare/descărcare sau chiar timpul până când bateria ajunge la SoH 0% și este considerată degradată (neutilizabilă).

2.3. Modelarea bateriilor

Modelarea bateriilor este un subiect important în domeniul estimării stării de degradare a bateriilor. Orice metodă de estimare se bazează direct sau indirect pe un model.

Cele mai întâlnite tipuri de modele sunt: modelul electric, modelul electrochimic, modelul matematic, modelul bazat pe ciclul de viață a bateriei.

2.3.1. Modelul electric

Modelul electric este cunoscut și sub forma modelului de circuit echivalent – modelul Randles sau Thevenin. Este compus dintr-o sursă de tensiune ideală și unul sau mai multe grupuri paralele de rezistențe – condensatori conectați în serie cu o rezistență [4]-[11].

Sursa ideală de tensiune reprezintă tensiunea în gol a bateriei, (*OCV* sau U_{OC}) și este un parametru destul de important ce se regăsește în centrul multor metode de estimare. Rezistența în serie R_{Ω} modelează rezistența internă a bateriei când la bornele bateriei se aplică un curent constant.

Grupul R_p - C_p modelează comportamentul dinamic al bateriei, când la bornele bateriei curentul variază




Fig. 2. Modelul Randles [4]

Sistemul de ecuații ce stă la baza acestui model este următorul [4]:

$$\begin{cases} U = U_{OC}(SoC) + IR_{\Omega} + U_p \\ I = \frac{U_p}{R_p} + C_p \frac{dU_p}{dt} \end{cases} \quad (2)$$

în care, U_{OC} este tensiunea în gol, R_{Ω} este rezistența internă a bateriei, R_p - C_p este grupul paralel rezistență – condensator, U este tensiunea de alimentare a circuitului, I este curentul din circuit.

2.3.2. Modelul electrochimic

Modelul electrochimic are ca scop aproximarea cât mai precisă a proceselor chimice ce au loc în interiorul celulei bateriei în timpul încărcării, descărcării și relaxării. Pentru o baterie de Li-Ion, din punct de vedere chimic, aceasta este compusă din trei elemente: electrodul negativ, separatorul (electrolitul) și electrodul pozitiv. În acest tip de baterie, ionii de Li se deplasează de la electrodul negativ spre cel pozitiv când bateria se descarcă, iar la încărcare de la electrodul pozitiv la cel negativ [12] - [13].

O variantă a modelului electrochimic derivat din modelul Randles de ordin 2 este prezentat în [12]. Impedanța bateriei se poate exprima prin următoarea ecuație:

$$Z_{batt} = j\omega L + \frac{Z_{n,SEI}}{S_n} + R_0 + \frac{Z_p}{S_p} \quad (3)$$

în care, Z_{batt} este impedanța bateriei, $Z_{n,SEI}$ este impedanța anodului, Z_p este impedanța catodului, iar S_n și S_p sunt ariile suprafețelor anodului și catodului. Modelul electrochimic poate fi extins și la celelalte tipuri de chimii, cum ar fi cele bazate pe Acid [15], Ni-MH.




Fig. 3. Modelul Electrochimic [12]

O abordare complexă este prezentată în [17]-[19] în care concentrația de ioni și reacțiile chimice sunt modelate prin ecuații diferențiale.

2.3.3. Modelul matematic

Modelul matematic folosește în general unul dintre parametri (electrici) ai bateriei pentru a modela degradarea acesteia [20]-[25]. În [20], estimarea degradării bateriei se face prin utilizarea curbelor CC-CV (curent constant – tensiune constantă) și o analiză de tip calendar. Pentru fiecare ciclu de încărcare, curentul poate fi exprimat folosind:

$$I(t) = Ae^{-Bt} + C \quad (4)$$

în care A , B , C sunt scalari ce reprezintă parametrii modelului.

Luând în considerare relația dintre parametrii modelului și degradarea capacității bateriei (C_{loss}), ecuația se poate rescrie:

$$I(t, C_{loss}) = A(C_{loss})e^{-B(C_{loss})t} + C(C_{loss}) \quad (5)$$

Autorii au arătat că există o relație liniară între capacitatea rămasă și parametrul B al modelului, o scădere a capacității bateriei duce la o scădere a valorii parametrului B.

În [21]-[22], tensiunea în gol a bateriei este folosită pentru a modela degradarea bateriei. Prin intermediul analizei incrementale (ICA) se trasează curbele ce denotă variația capacității cu tensiunea în gol. Ecuația ce stă la baza modelului este:

$$OCV(z) = K_0 - \frac{K_1}{z} - K_2 z + K_3 \ln(z) + K_4 \ln(1-z) \quad (6)$$

în care K_{0-4} , sunt parametri ai modelului, z este valoarea normalizată a SoC. Pentru a obține rezultate mai bune se poate folosi o variantă complexă a ecuației:

$$OCV(z) = K_0 - K_1 \frac{1}{1 + e^{a_1(z-\beta_1)}} - K_2 \frac{1}{1 + e^{a_2(z-\beta_2)}} + K_3 \frac{1}{1 + e^{a_3(z-1)}} + K_4 \frac{1}{1 + e^{a_4 z}} + K_5 z \quad (7)$$

În [23], capacitatea bateriei este estimată folosind curbele ridicate din măsurători la fiecare ciclu al bateriei. Sunt evaluate trei modele – cel exponențial, cel polinomial, și cel hibrid:

$$\begin{aligned} C_{Ak} &= C_{Ak1} + C_{Ak2} = a_1 e^{a_2 k} + a_3 e^{a_4 k} \\ C_{Bk} &= C_{Bk1} + C_{Bk2} = \beta_1 k^2 + \beta_2 k + \beta_3 \\ C_{Ck} &= \gamma_1 e^{\gamma_2 k} + \gamma_3 k^2 + \gamma_4 \end{aligned} \quad (8)$$

în care C_{Ak} , C_{Bk} și C_{Ck} sunt valorile capacității bateriei, k reprezintă ciclul de descărcare, iar $a_1, a_2, a_3, a_4; \beta_1, \beta_2, \beta_3; \gamma_1, \gamma_2, \gamma_3$, sunt parametri modelului. Experimentele arată că modelul hibrid oferă o acuratețe mai bună pentru predicția capacității.

2.3.4. Modelul bazat pe ciclul de viață a bateriei

Modelul bazat pe ciclul de viață a bateriei este un alt tip de model folosit pentru determinarea degradării bateriei. Acest tip de model urmărește parametri bateriei și relația dintre aceștia și procesul de îmbătrânire. Starea de degradare se determină prin observații multiple după teste offline. Acest mod este diferit de celelalte modele care monitorizează parametri în timp real și estimează starea de degradare bazat pe valori instantanee ale parametrilor.

Un astfel de model este utilizat în [26]. Parametrii folosiți sunt: temperatura bateriei, curentul de încărcare, curentul de descărcare, nivelul de descărcare. Este analizat impactul acestor parametri asupra capacității bateriei. Modelul propus a fost dezvoltat și validat în Matlab.

Autorii din [16] propun să monitorizeze următorii parametri ai bateriei: temperatura, capacitatea, numărul de cicluri încărcare/descărcare. Pentru predicția stării de degradare sunt folosiți algoritmi bazați pe vectori suport. Aceste tipuri de tehnici implică antrenarea pe un set imens de date. Pentru a scurta timpul de

observare, autorii au folosit teste de îmbătrânire accelerată. Rămâne discutabil dacă acest teste se mapează direct pe condițiile de utilizare reale ale bateriei.

În [27]-[28], modelul de ciclu de viață se bazează pe modele de fiabilitate. Aceste modele sunt folosite împreună cu celelalte tipuri de modele pentru a îmbunătăți estimarea stării de degradare.

2.4. Rețele neuronale pentru estimarea seriilor de timp

2.4.1. Taxonomia problemelor legate de estimarea seriilor de timp

Fie un set de date de intrare $X = \{x_1, x_2, \dots, x_n\}$, pentru care cunoaștem valorile de ieșire $Y = \{y_1, y_2, \dots, y_m\}$. Estimarea seriilor de timp presupune găsirea unei funcții $f(X) = Y$, care să realizeze o mapare cât mai fidelă între valorile de intrare și cele de ieșire.

Algoritmii de estimare a seriilor de timp bazați pe învățare automată presupun existența unui set de date cunoscut pentru care se deduce funcția de estimare f . Performanța algoritmului se obține aplicând funcția obținută pe un set de date necunoscut, și urmărind diferite metrice și criterii de evaluare.

Problemele de predicție a seriilor de timp presupun analizarea mai multor aspecte [29], câteva dintre cele mai importante fiind enumerate în continuare:

- **Intrări vs. ieșiri** – în general o predicție presupune folosirea unor observații anterioare pentru a estima observații viitoare. Intrările sunt datele obținute în observația curentă pentru care se face predicția – valorile de ieșire. Nu trebuie confundate intrările cu datele pentru antrenarea algoritmului.
- **Date endogene vs. date exogene** – variabilele de intrare se consideră endogene dacă sunt afectate de alte variabile și variabilele de ieșire depind de acestea. De exemplu în seriile de timp, o observație la timpul t este dependentă de cea de la $t - 1$, cea de la $t - 1$ depinde de $t - 2$ etc. O variabilă de intrare este exogenă dacă este independentă de celelalte variabile din sistem și variabila de ieșire depinde de aceasta.
- **Regresie vs. Clasificare** – în cadrul problemelor de regresie, estimarea obține o valoare. Aceasta este numerică și poate fi asimilată cu un volum, un preț, etc. Problemele de clasificare sunt cele în care valoarea predicției este o categorie. O categorie de date conține etichete bine definite – de exemplu, mare, mic, rece, cald, albastru, verde, etc.
- **Date structurate vs. Nestructurate** – de multe ori este important de analizat setul de date deoarece acesta poate conține tipare – de repetiție, etc. care poate să ușureze într-o anumită măsură algoritmul de predicție. Deci putem spune că datele care urmează un anumit tipar sau ciclicitate sunt date structurate, pe când cele care nu prezintă o astfel de proprietate sunt nestructurate.
- **Predicție univariată vs. Multivariată** – o singură variabilă măsurată în timp se consideră univariată. Predicția univariată presupune predicția unei singure variabile, pe când cea multivariată presupune predicția mai multor variabile.

- **Predicție într-un singur pas vs. multi-pas** – algoritmul de predicție poate să estimeze valoarea corespunzătoare următorului moment de timp sau poate să prezică un set de date ce se întinde pe mai multe instanțe de timp.
- **Model static vs. dinamic** – un model se consideră static dacă acesta nu se modifică între predicții. Un model dinamic este un model care se modifică între predicții, în general își ajustează parametrii cu scopul de a crește acuratețea estimării.
- **Date continue vs. discontinue** – un set de date pentru care observațiile sunt distribuite uniform în timp, se consideră set de date continue. Cel de-al doilea tip presupune existența unor intervale în care datele lipsesc sau sunt corupte. În acest caz este nevoie de formatarea datelor în așa fel încât să poată fi aplicate metode de estimare.

2.4.2. Rețele neuronale de tip MLP

Rețelele neuronale de tip MLP (Multilayer perceptron, sau perceptron multi-strat) sunt o subclasă a rețelelor neuronale de tip *feed-forward* (FFNN) și au o structură simplă în care există o singură cale de date de la intrare spre ieșire prin care se transformă datele de intrare în date de ieșire [30]-[31]. Arhitectura nu permite legături de reacție care să lege o parte din valoarea ieșirilor de intrări după cum se poate observa în figura de mai jos:

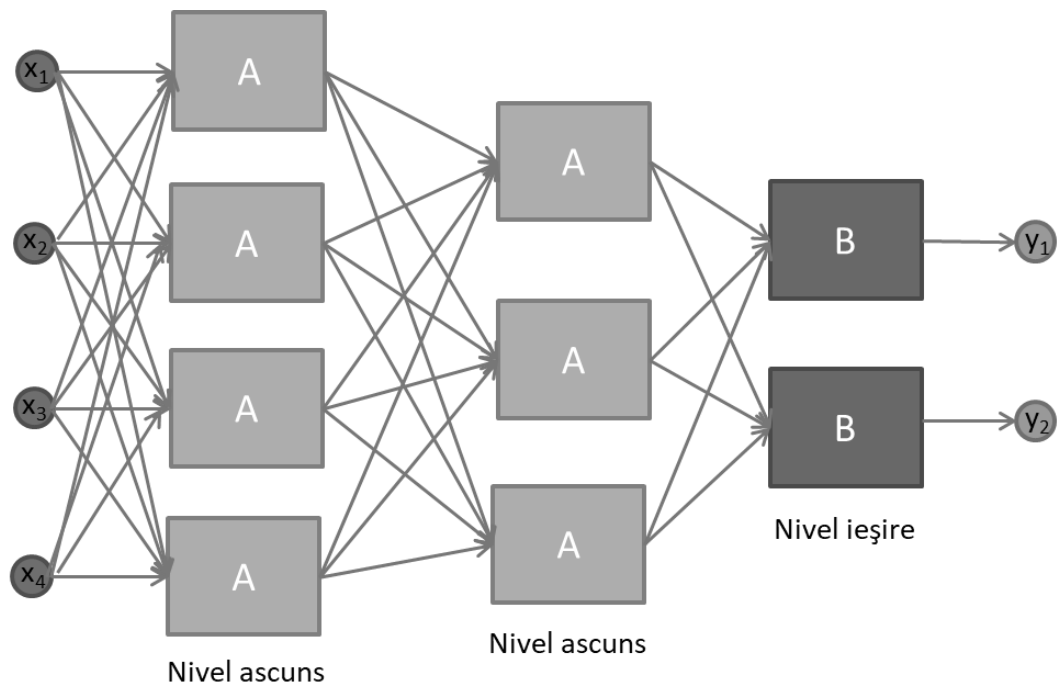


Fig. 4. Arhitectura rețelei neuronale MLP [30]

În figura anterioară am reprezentat arhitectura rețelelor de tip FFNN cu două nivele ascunde cu funcția de activare A, un nivel de ieșire cu funcția de activare B, setul de intrări $x_i, i = 1..4$ și setul de ieșiri, $y_j, j = 1..2$.

O astfel de rețea neuronală se poate transforma ușor într-un predictor dacă se aleg funcțiile de activare în mod corespunzător [30].

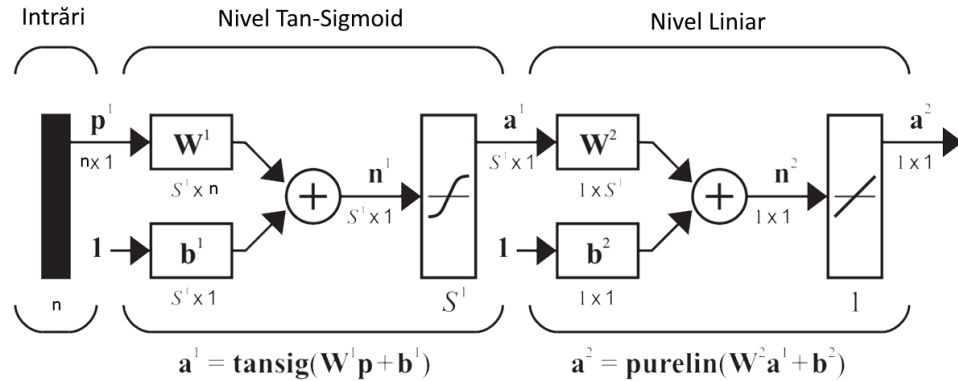


Fig. 5. Calea de date și operațiile din cadrul rețelei neuronale MLP [30]

În Fig. 5 se pot distinge următoarele mărimi: \mathbf{p} este vectorul de intrare, \mathbf{W}^1 este matricea ponderilor pentru nivelul 1, \mathbf{b}^1 este vectorul de bias-uri pentru nivelul 1, \mathbf{n}^1 este vectorul de intrare în funcția de activare al nivelului 1, \mathbf{a}^1 este ieșirea din nivelul 1 și vectorul de intrare pentru nivelul 2, \mathbf{W}^2 este matricea ponderilor pentru nivelul 2, \mathbf{b}^2 este vectorul bias-urilor pentru nivelul 2, \mathbf{n}^2 este vectorul de intrare în funcția de ieșire pentru nivelul 2, iar \mathbf{a}^2 este ieșirea din nivelul 2.

Funcția de activare pentru nivelul ascuns este tan-sigmoid, iar pentru nivelul de ieșire este funcția liniară:

$$\text{tansig}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (9)$$

$$\text{lin}(x) = ax + b$$

2.4.3. Rețele neuronale de tip LSTM

Rețelele neuronale de tip LSTM (Long Short-Term Memory) sunt un caz particular de rețele neuronale recurente menite să contribuie la rezolvarea limitărilor MLP [32]. O listă a limitărilor MLP este următoarea:

- Dimensiunea datelor de intrare este fixă;
- Dimensiunea datelor de ieșire este fixă;
- Nu țin cont de dimensiunea temporală;

- Scalare ineficientă în cazul predicției Multivariate;
- Nu țin cont de starea sistemului – FFNN învață o singură funcție fixă și generală pe care o aplică intrărilor.

În figura de mai jos este prezentată o arhitectură de rețea neuronală de tip LSTM cu două nivele ascunse și un nivel de agregare.

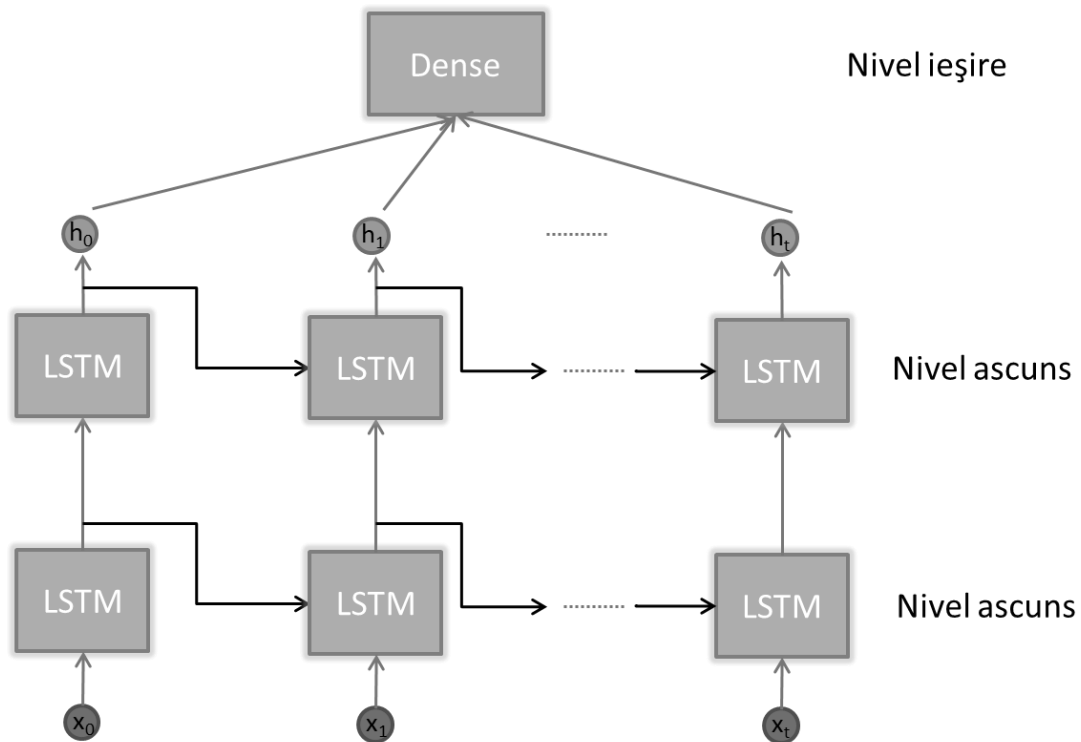


Fig. 6. Arhitectura rețelei neuronale LSTM

O particularitate importantă a acestor rețele este că celula de bază a fost modificată în așa fel încât să fie capabilă de a învăța dependențele pe termen lung. Prin intermediul porților se pot controla câtă informație recentă și cu mult anterioară poate fi folosită pentru a genera ieșirea curentă [33]-[34].

Structura celulei și căile de date sunt prezentate în figura următoare [35]:




Fig. 7. Căile de date dintr-o rețea LSTM [35]

Una dintre cele mai importante căi este cea a stării celulei. Aceasta este calea de date prezentată în figura de mai jos:




Fig. 8. Starea celulei LSTM [35]

Calea de stare a celulei LSTM este o cale directă liniară ce leagă starea de la momentul t , C_t , cu cea de la momentul de timp $t - 1$, C_{t-1} . Valoarea stării celulei se actualizează prin adăugarea sau înlăturarea de informații prin intermediul porților. Aceste porți controlează dacă informația este lăsată să treacă sau nu și conțin funcția de activare sigmoid într-un bloc multiplicativ:




Fig. 9. Poartă în cadrul celulei [35]

Controlul memoriei pe termen lung a celulei LSTM este realizat cu ajutorul porții din figura 9 și a conexiunilor din figura 10. Modelarea matematică a acestui proces este reprezentată prin funcția din (10):

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (10)$$

în care f_t este funcția „uitării” (*forget function*), σ este funcția sigmoid, \mathbf{W}_f este matricea ponderilor porții f , h_{t-1} este ieșirea de la momentul de timp $t - 1$, x_t este intrarea de la momentul t , b_f este biasul porții f .




Fig. 10. Controlul memoriei pe termen lung [35]

În Fig 9. este reprezentat modul în care se reține informația ce se păstrează în cadrul celulei. Controlul memoriei pe termen scurt este format dintr-un nivel sigmoid și un vector de valori candidate pentru a fi adăugate în final stării actuale a celulei. Din punct de vedere formal, controlul memoriei pe termen scurt este definit de relațiile din (11):

$$\begin{aligned} i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \end{aligned} \quad (11)$$

în care, i_t reprezintă poarta de intrare și controlează dacă valorile candidate intră sau nu în starea actuală a celulei, \mathbf{W}_i – matricea ponderilor porții de intrare, h_{t-1} valoarea ieșirii de la momentul $t - 1$, x_t valoarea de intrare la momentul t , b_i – biasul porții de intrare, \tilde{C}_t – vectorul valorilor candidate pentru actualizarea stării celulei, \mathbf{W}_C matricea ponderilor valorilor candidate, b_C – biasul valorilor candidate.




Fig. 11. Controlul memoriei pe termen scurt [35]

Combinând ecuațiile (10) și (11) putem defini ecuația stării celulei LSTM (12), reprezentată grafic în Fig. 12.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (12)$$




Fig. 12. Actualizarea stării celulei LSTM [35]

Ultima cale de date este cea de ieșire. Printr-un nivel sigmoid se decide ce valori se vor expune la ieșirea celulei (vezi Fig. 13.). Acestea se calculează conform (13):

$$\begin{aligned} o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t &= o_t * \tanh(C_t) \end{aligned} \quad (13)$$




Fig. 13. Calea de date pentru ieșire [35]

2.4.4. Rețele neuronale de tip GRU

În figura de mai jos este prezentată o rețea neuronală formată din două nivele ascunse de tip GRU și un nivel de agregare.

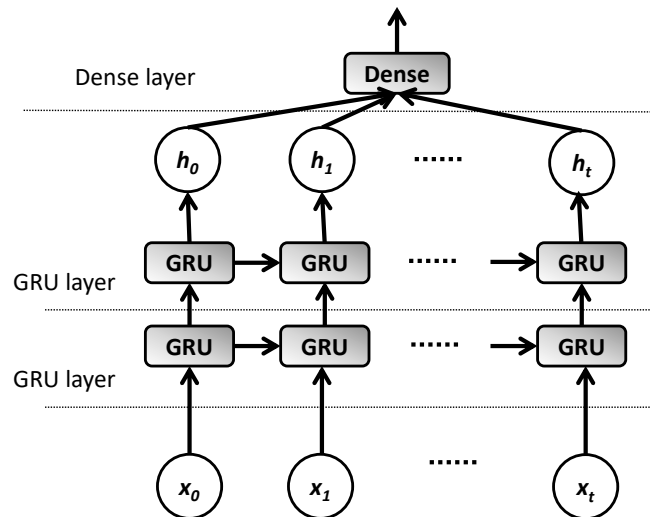


Fig. 14. Arhitectura rețelei neuronale GRU

Celula de bază a rețelelor de tip GRU este asemănătoare cu cea a celulelor de tip LSTM, o modificare importantă este că nu se mai ia în considerare starea celulei. Rețelele neuronale de tip GRU folosesc două porți: poarta de actualizare prin care se controlează cantitatea de informație din trecut ce trebuie luată în considerare și poarta de resetare care controlează câtă informație va fi uitată, respectiv nu va fi luată în considerare.

În figura 15 este detaliată structura internă și calea de date în interiorul unei celule de tip GRU [3].




Fig. 15. Structura internă și căile de date din cadrul celei GRU [3]

Ieșirea nivelului ascuns h , la instanța de timp k , depinde de ieșirea de la momentul $k - 1$ și de o valoare de ieșire candidat, notată cu \tilde{h}_k , utilizând relația liniară:

$$h_k = (1 - z_k)h_{k-1} + z_k \tilde{h}_k \quad (14)$$

În care z_k este valoarea la poartă de actualizare, definită prin ecuația de activare:

$$z_k = \sigma(W_z[h_{k-1} \ x_k]) \quad (15)$$

Valoarea z_k controlează cât de mult ieșirea curentă depinde de ieșirea anterioară sau de ieșirea candidată. Aceasta se definește prin următoarea ecuație:

$$\tilde{h}_k = \tanh(W_h[r_k h_{k-1} \ x_k]) \quad (16)$$

unde r_k este valoarea la poartă de ieșire:

$$r_k = \sigma(W_r[h_{k-1} \ x_k]) \quad (17)$$

Poarta de resetare controlează cât de mult ieșirea candidată depinde de ieșirea anterioară. \mathbf{W}_z , \mathbf{W}_h , \mathbf{W}_r sunt matricile ponderilor pentru poarta de actualizare, pentru cea de resetare, respectiv pentru ieșirea candidat.

În [36] sunt descrise ecuațiile celulelor LSTM și GRU în variantă vectorizată. Aceste ecuații sunt cele mai des întâlnite în implementările de sisteme cadru pentru definirea și modelarea rețelelor neuronale. Aceste ecuații pot fi paralelizate în scopul de a optimiza timpul de învățare, respectiv timpul de rulare.

Astfel, pentru rețelele de tip LSTM avem următorul sistem de ecuații:

$$\begin{cases} c_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t \\ \tilde{c}_t = g(W_c x_t + U_c h_{t-1} + b_c) \\ h_t = o_t \otimes g(c_t) \\ i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \\ f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \\ o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \end{cases} \quad (18)$$

iar pentru rețelele neuronale de tip GRU, acest sistem de ecuații devine:

$$\begin{cases} h_t = (1 - z_t) \otimes h_{t-1} + z_t \otimes \tilde{h}_t \\ \tilde{h}_t = g(W_h x_t + U_h (r_t \otimes h_{t-1} + b_h)) \\ z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \\ r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \end{cases} \quad (19)$$

3. ABORDĂRI CURENTE PRIVIND METODELE PENTRU EVALUAREA STĂRII DE DEGRADARE A BATERIILOR

3.1. Discuție asupra metodelor existente de estimare a stării de degradare a bateriilor

În literatură există o preocupare activă în ceea ce privește problema estimării stării de sănătate a bateriilor dovedit de numărul mare de articole ce tratează probleme din acest domeniu. În figura 16 este prezentată o clasificare a metodelor de estimare a stării de sănătate a bateriilor conform [37]-[46].

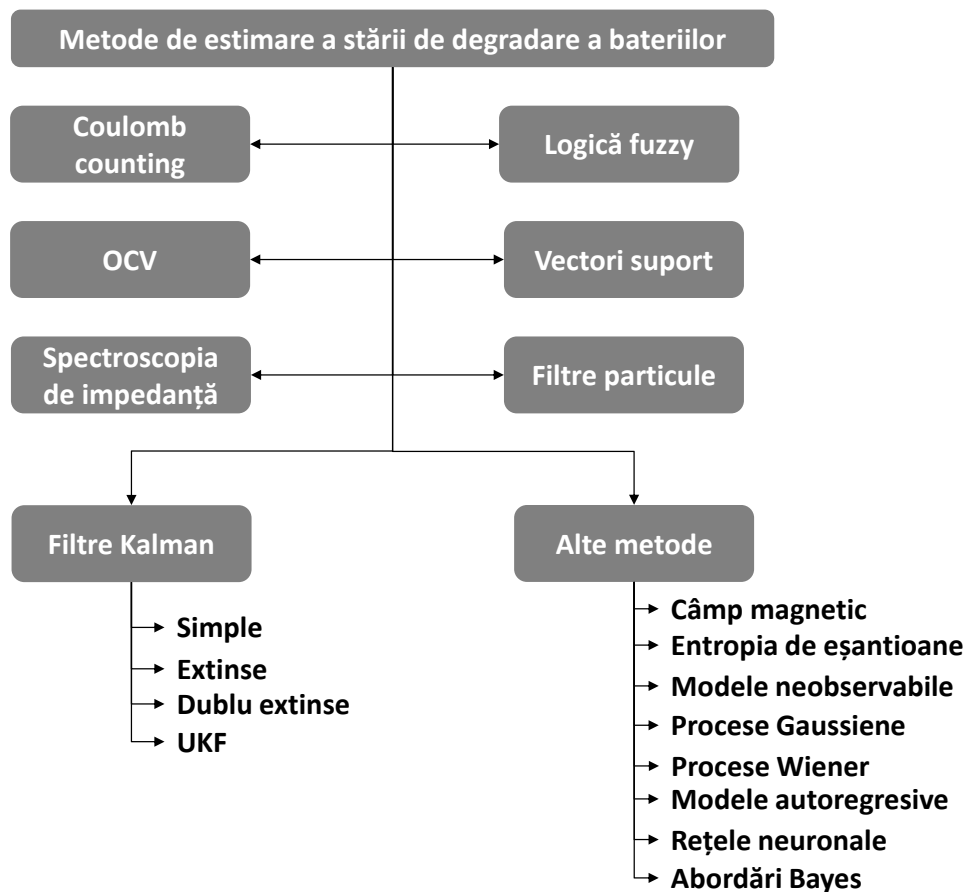


Fig. 16. Clasificarea metodelor de estimare a stării de degradare a bateriilor

3.1.1. Coulomb Counting

Este una dintre cele mai comune metode pentru estimarea SOH, estimare ce se desfășoară în doi pași. În primul pas se calculează capacitatea de descărcare a bateriei, prin integrarea curentului de descărcare în timp. În pasul al doilea, se calculează valoarea SOH prin raportarea capacității de descărcare la valoarea capacității nominale a bateriei

$$\begin{cases} Q_{discharge} = \int_0^T I(t)dt \\ SoH [\%] = \frac{Q_{discharge}}{Q_{rated}} \times 100\% \end{cases} \quad (20)$$

Principalii parametri monitorizați ai bateriei sunt: curentul de încărcare/descărcare, tensiunea bateriei, capacitatea bateriei, temperatura bateriei. Metoda poate fi transpusă adaptiv prin calcularea celor doi parametri din ecuație în timpul ciclurilor de încărcare/descărcare.

În [47] autorii au observat că valoarea capacității de descărcare scade o dată cu creșterea ciclului de încărcare/descărcare. În consecință funcția SOH are un trend descrescător, pentru o valoare de sub 80%, bateria se consideră inutilizabilă. Acuratețea metodei depinde foarte mult de instrumentele de măsură care este indicat să fie calibrate periodic pentru a nu introduce erori suplimentare.

Tot în [47] autorii susțin că acuratețea depinde doar de acuratețea cu care se măsoară curentul și capacitatea inițială a bateriei. Se introduce o nouă metrică pentru caracterizarea ciclului de descărcare, și anume nivelul de descărcare (DoD):

$$D_{OD} = \frac{Q_{released}}{Q_{rated}} \times 100\% \quad (21)$$

unde $Q_{released}$ este capacitatea descărcată din baterie, Q_{rated} capacitatea nominală a acesteia. În orice moment de timp, D_{OD} se poate exprima:

$$\begin{cases} D_{OD}(t) = D_{OD}(t) + \eta \Delta D_{OD}(t) \\ \Delta D_{OD}(t) = \frac{-\int_{t_0}^{t_0+\tau} I_b(t)dt}{Q_{rated}} \times 100\% \end{cases} \quad (22)$$

în care I_b este curentul bateriei (încărcare/descărcare), iar η este factorul de eficiență.

SOH este definit ca valoarea DoD când bateria este degradată. În fiecare ciclu de încărcare/descărcare, valoarea DoD este compensată cu valoarea eficienței la încărcare/descărcare. În paralel, o recalibrare se face la fiecare stare terminală de încărcare/descărcare. Printre avantajele acestei metode se pot aminti costul redus al echipamentelor, putere de procesare redusă.

În [48] este prezentat un sistem de management al bateriilor complet, în care SOC și SOH sunt calculate bazat de coulomb counting. Precizia este comparată cu o versiune modificată a metodei OCV combinată cu filtru Kalman pentru

estimarea SOC. Erorile sunt calculate la diferiți curenți de încărcare/descărcare și se situează în intervalul [-3%, +3%].

3.1.2. OCV

Această metodă se bazează pe ideea definirii SOH în funcție de tensiunea în gol a bateriei. Modelul simplificat din [9] definește U_{OCV} ca în figura de mai jos:

$$U_{OCV} = U + I \cdot R \quad (23)$$

în care U_{ocv} este tensiunea în gol a bateriei, I este curentul bateriei, R este rezistența internă a bateriei și U este tensiunea la borne.




Fig. 17. Modelul electric simplificat

Se pot distinge două variante: metoda în timp real – online – în care predicția se face bazat pe măsurători în timp real al parametrilor bateriei; metoda a priori – offline – se bazează pe o analiză a curbelor OCV-SOH, din care reiese relația dintre OCV și SOH.

Așa cum este prezentat în [21] și [22], autorii au realizat un set extins de teste pentru a obține curbele OCV-SOH.

În [9], autorii s-au concentrat pe analiza influenței temperaturii în construcția curbelor OCV-SOC. Influența temperaturii nu este de neglijat atunci când este nevoie de o precizie cât mai mare. Autorii prezintă o metodă de a determina curbele OCV-SOC în relație cu temperatura. Curbele OCV-SOC se pot transforma cu ușurință pentru a fi utilizate la determinarea SOH. În ciuda unei precizii foarte bune de estimare, acest tip de metodă implică multe teste de laborator.

Varianta în timp real – online – se bazează pe OCV ca și parametru al modelului electric prezentat anterior, determinat prin identificarea sistemelor. Erorile de estimare sunt influențate de SoC inițial al bateriei și de temperatură. Dacă diferența dintre SoC inițial real și cel utilizat în calcule este menținută cât mai redusă, eroarea de estimare este de asemenea mică. O temperatură scăzută introduce o eroare medie pătratică (RMSE) în intervalul 5% - 25%.

Metoda prezentată în [6], este o combinație între parametri electrici pentru estimarea SOC și SOH. Algoritmul este destinat bateriilor cu mai multe celule și este bazat pe măsurarea puterii electrice. Eroarea de estimare depinde doar de perioada pentru care se face predicția, când supratensiunea ce apare la fenomenul de difuzie a bateriei poate influența SOC.

În [4] autorii prezintă câteva dezavantaje al estimării SoH prin intermediul parametrului de tensiune în gol. Aceștia susțin că în condiții reale este foarte de greu de determinat acest parametru, propunând o metodă simplificată în care OCV este eliminat ca parametru, iar estimarea de face bazându-se pe curbele CC-CV(curent constant – tensiune constantă). Această modificare duce la simplificarea algoritmului, reduce puterea de procesare necesară estimării precum și reducerea costurilor hardware.

Autorii din [37] consideră că OCV este foarte eficientă dacă se folosește în combinație cu metoda prezentată anterior: coulomb counting. În [22], autorii folosesc parametri exponențiali în combinație cu OCV pentru estimarea SoH cu ajutorul capacității incrementale. Această combinație produce o eroarea de estimare ce se apropie de 1%.

3.1.3. Spectroscopia de impedanță

Metoda spectroscopiei impedanței (EIS) permite determinarea cu o precizie foarte mare a impedanței interne a bateriei utilizând un spectru larg de frecvențe la un curent mic al bateriei. În literatură de specialitate este demonstrat că măsurătorile EIS sunt un indicator foarte bun pentru SoC, din care se poate estima SOH.

În figura următoare este prezentat impedanța bateriei în domeniul complex:




Fig. 18. Diagrama Niquist obținută prin EIS [16][18]

Una dintre cele mai comune utilizări ale EIS este identificarea parametrilor unui model electrochimic. Acest lucru este detaliat în [12], aplicat celulelor de tip Li-Ion. Modelul are 16 parametri din care 6 sunt calculați a-priori și considerați constanți, ceilalți 10 parametri sunt determinați cu ajutorul HMPISO, o metodă de analiză bazată pe filtre de particule.

Măsurătorile EIS sunt făcute pe baterii de timp Li-Ion încărcate la 100% și 50%, folosind un spectru de frecvență de 0.025Hz – 4kHz. Modelul identificat este comparat cu modelul Randles, demonstrându-se o precizie de calcul al parametrilor de 8 ori mai mare. În articol nu este prezentată o metodă completă de estimare a SOH, dar sunt sugerate două modele ce ar putea fi folosite în acest sens.

În [16], autorii prezintă o fuziune între metoda EIS și RNN, în care RNN este folosit exclusiv pentru predicția SoH și RUL a bateriilor. EIS este folosită pentru o analiză offline, pentru calcularea parametrilor circuitului echivalent. Modelul electrochimic propus conține 5 parametri. Doi dintre aceștia sunt folosiți pentru a modela rezistența ohmică R_1 și cea dependentă de SOC, R_2 . Modelul conține și doi parametri ce sunt folosiți la modelarea difuziei: CPE1 și CPE2, care sunt dependenți de SOC. Măsurătorile EIS sunt determinate la 25 grade C, iar spectrul de frecvență folosit este [0,01Hz – 10kHz]. Modelul este validat pentru vehicule electrice hibride, demonstrându-se totodată că este destul de simplu pentru a fi implementat pentru orice sistem de management al bateriei.

Predicția se face folosit RNN având ca intrare măsurătorile RNN. Eroarea medie rezultată de este de 2.1%.

O abordare nouă folosind EIS este prezentată în [20]. Autorii propun o metodă de estimare a RUL bazată pe metoda degradării calendaristice a celulelor Li-Ion. Experimentele au fost realizate la 3 temperaturi diferite și 3 SoC diferite, rezultatele măsurătorilor EIS au demonstrat dependența SOH de temperatură și de SoC. Analizând curbele EIS, autorii au observat că impedanța reală la 0,1 Hz variază exponențial cu SoH, și poate fi folosită pentru predicția acestuia. În figura următoare se prezintă această dependență exponențială:




Fig. 19. Impedanța estimată și cea măsurată partea reală [16]

Rezultatele prezentate sugerează că acest parametru identificat prin măsurători EIS poate fi folosit cu succes pentru predicția SoH, modelul sugerat fiind unul mult mai simplu decât cel electrochimic.

3.1.4. Filtre Kalman

Filtrele Kalman reprezintă o metodă performantă de estimare a stărilor unui proces. Este compus din două părți: partea de predicție și cea de actualizare. Starea procesului este estimată în faza de predicție. În faza de actualizare, filtrul obține o reacție din măsurători (considerate afectate de zgomot de tip Gaussian) [49]. Ecuațiile standard al unui filtru Kalman sunt următoarele:

$$\begin{cases} \hat{x}(t|t-1) = F_t \hat{x}(t-1|t-1) + B_t u_t \\ P(t|t-1) = F_t P(t-1|t-1) + Q_t \\ \hat{x}(t) = \hat{x}(t|t-1) + K_t (y_t - H_t \hat{x}(t|t-1)) \\ K_t = P(t|t-1) H_t^T (H_t P(t|t-1) H_t^T + R_t)^{-1} \\ P(t) = P(t|t-1) - K_t H_t P(t|t-1) \end{cases} \quad (24)$$

în care: \hat{x} este starea estimată, F este matricea de tranziție a stărilor, B matricea de control, u este vectorul de control, P este matricea de varianță a stărilor, Q este matricea de varianță a procesului, y este vectorul de măsurare, H este matricea de măsurare, K este amplificarea Kalman și R este matricea de varianță a măsurătorilor.

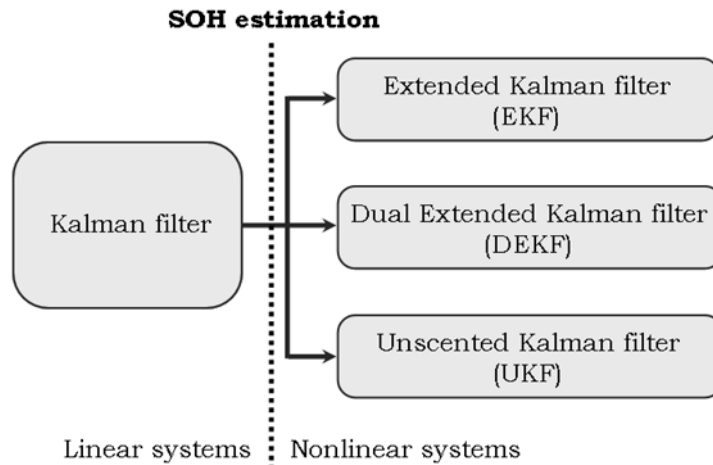


Fig. 20. Variante de filtre Kalman utilizare în sisteme neliniare

Filtrele Kalman sunt utilizare de obicei în sistem liniare. Pentru sistemele neliniare, cum e cel pentru estimarea SOH a bateriei, există în literatură câteva versiuni modificate.

Filtrul Kalman extins este folosit pentru predicția stărilor unui proces neliniare, în care ecuațiile de tranziție și de măsurare sunt neliniare, dar trebuie să

fie diferențiabile. Pentru estimare SOH, filtrul Kalman dual extins este format dintr-un filtru Kalman pentru predicția SOC și celălalt pentru predicția capacității bateriei. Filtrul Kalman U cunoscut și sub forma de filtru Kalman bazat pe puncte sigma elimină câteva dezavantaje ale filtrelor Kalman extinse și îmbunătățește performanța. În acest caz, funcția de distribuție a probabilității este estimată prin câteva puncte sigma, care reprezintă un subset de puncte calculate în așa fel să fie apropiate de valoarea mediană. Transformarea neliniară acestor puncte vor genera estimarea covarianței mediane.

În [50] și [51] autorii folosesc un model Randles de ordin 2 pentru a obține ecuațiile de stare a filtrului Kalman extins. În primul caz, SOH este calculat bazat pe SOC, în al doilea caz, SOH este calculat bazat pe impedanța internă a bateriei. Ecuațiile modelului sunt:

$$\begin{cases} \begin{pmatrix} SoC_k \\ V_{1,k} \\ V_{2,k} \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_1 C_1} & 0 \\ 0 & 0 & 1 - \frac{\Delta t}{R_2 C_2} \end{pmatrix} \begin{pmatrix} SoC_{k-1} \\ V_{1,k-1} \\ V_{2,k-1} \end{pmatrix} + \begin{pmatrix} \frac{\Delta t}{C_{bat}} \\ \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_1} \end{pmatrix} \\ V_{bat,k} = V_{OC}(SoC_k) + V_{1,k} + V_{2,k} + R_0 I_{bat,k} \end{cases} \quad (25)$$

respectiv,

$$\begin{cases} \begin{pmatrix} V_{1,k+1} \\ V_{2,k+1} \\ R_{0,k+1} \end{pmatrix} = \begin{pmatrix} e^{-\frac{T}{R_1 C_1}} & 0 & 0 \\ 0 & e^{-\frac{T}{R_2 C_2}} & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} V_{1,k} \\ V_{2,k} \\ R_{0,k} \end{pmatrix} + \begin{pmatrix} R_1 \left(1 - e^{-\frac{T}{R_1 C_1}} \right) \\ R_2 \left(1 - e^{-\frac{T}{R_2 C_2}} \right) \\ 0 \end{pmatrix} I_{bat,k} \\ (V_{cell,k} - V_{OC,k})' = (1 \ 1 \ 0)x + R_{0,k} I_{bat,k} \end{cases} \quad (26)$$

în care SoC_k este SOC la momentul k , R_0 , R_1 , R_2 , C_1 , și C_2 sunt parametri modelului electric Randles de ordin 2 care modelează impedanța bateriei, $V_{1,k}$ și $V_{2,k}$ sunt componente ale tensiunilor modelului Randle la momentul k , V_{OC} este tensiunea în gol a bateriei, $I_{bat,k}$ este curentul bateriei, V_{bat} este tensiunea la borne a baterie, $V_{cell,k}$ este tensiunea în gol per celulă, și $x = (V_{1,k} \ V_{2,k} \ R_0 \ k)^T$ variabila de stare. În ambele cazuri, eroare de estimare este sub 4%.

În [52], filtrul Kalman extins este folosit pentru a modela parametri unei baterii Li-ion cum ar fi: tensiunea la borne, tensiunea în gol și SOC. Autorii se

bazează pe baterii folosite la mașini electrice. Rezultatele experimentale arată o eroare de estimare de aprox. 1%.

Filtrul Kalman dual extins este prezentat în [53] și [54]. Două filtre Kalman sunt folosite: unul pentru estimarea SOC, celălalt pentru estimarea altor parametri ai bateriei, cum ar fi capacitatea. Figura de mai jos prezintă structura unui filtru Kalman dual extins:

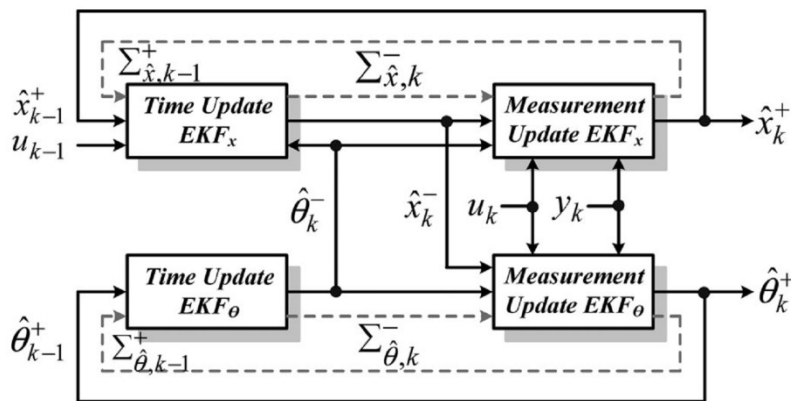


Fig. 21. Arhitectura Filtrului Kalman Dual

Filtrul este bazat pe un model electric Randles de ordin 2. Autorii susțin că o dată cu creșterea ordinului modelului electric, estimarea devine greu de realizat datorită complexității în aplicații real-time. În primul articol, erorile de estimare se situează între $\pm 5\%$. Eroarea de estimare în cel de-al doilea articol se situează în jurul valorii de 2%.

Filtrul Kalman U este prezentat în [55] și [56] pentru estimarea SoH. Modelul electric al bateriei utilizat este Randles de ordin 2. Acest tip de filtru a fost introdus pentru a aborda câteva probleme pe care le prezintă filtrele Kalman extinse [57]. Printre probleme se numără probabilitatea destul de mare ca filtrul să fie divergent dacă starea inițială nu este specificată în mod corect, rezultând un model eronat al procesului. O altă problemă constituie aproximarea mediei posterioare și a matricei de covarianță care pot să ducă la erori semnificative.

În [55], autorii compară performanța estimării SOH utilizând filtre Kalman U cu cea a coulomb counting. Filtrul Kalman U se adaptează perfect la neliniaritățile bateriei și rezolvă problemele celei de-a doua metode (acumulările de erori), rezultând o estimare a SoH aproape de cea reală. Eroare de estimare se situează între 2.2 și 2.9%.

În [56], filtrul Kalman U este folosit în combinație cu algoritmul SVR. SVR este folosit pentru a determina valoarea capacității inițiale ce se introduce la intrarea filtrului Kalman U. Acest lucru este făcut offline, bazat pe analiza curbelor de îmbătrânire. Performanța algoritmului este sub 1%.

În [58], filtrul Kalman U este aplicat modelului electrochimic. Autorii monitorizează răspunsul tensiunii bateriei la pulsuri de curent și rezistența internă a acesteia. Metoda este adaptivă, cu un timp de calcul inițial de 40 min, până când valorile încep să convergă la valorile reale a parametrilor.

Autorii din [59] propun o metodă de estimare a SOH obținut prin combinația filtrului Kalman extins și metoda analizei cvadractice. Ecuațiile filtrului Kalman sunt obținute dintr-un model electric de ordin unu. Parametri bateriei obținuți prin EKF, sunt folosiți în clasificarea: baterii nefolosite, puțin folosite, foarte folosite. Eroarea de clasificare atinge un maxim de 8.3%.

În [60] estimarea SoH folosește un filtru EKF bazat pe capacitatea și rezistența de difuzie. Metoda propusă este validată prin multiple teste de laborator prin măsurarea offline a parametrilor bateriei și ridicarea curbelor de îmbătrânire. Eroarea de estimare este de $\pm 5\%$.

În [61], autorii folosesc un filtru Kalman bazat pe diferență centrală (CDKF). Acesta din urmă estimează mai precis neliniaritățile bateriei. CDKF este o variantă de SPKF adaptat pentru utilizarea în implementări practice datorită numărului redus de parametri.

3.1.5. Logică Fuzzy

Logica fuzzy este un concept matematic care generalizează logica și mulțimile booleene. Ideea de bază este că se permite elementelor din mulțimile fuzzy să aibă grade de apartenență la acea mulțime. O funcție de apartenență este aplicată fiecărui element x dintr-o mulțime A , iar valoarea funcției este situată în intervalul $[0, 1]$, ceea ce reprezintă cât de mult aparține x la mulțimea A . Logica fuzzy se bazează pe operatorii booleeni ȘI, SAU și NEGAT, definiți în tabelul de mai jos:

Tabel 1. Operatori de logica fuzzy

Operație	Rezultat
$x \text{ ȘI } y$	$\min(x, y)$
$x \text{ SAU } y$	$\max(x, y)$
$x \text{ NEGAT}$	$1 - x$

Logica fuzzy se poate aplica și în cazul estimării SOH, dacă se definesc câteva funcții de apartenență pentru SoH, cum ar fi *stare bună*, *stare acceptabilă*, *stare degradată*.

Unul dintre articolele care folosesc această metodă de estimare este [62]. Autorii propun un model derivat din cel electrochimic, iar estimarea se face pentru SOC, SOH se face folosind trei metode: ARMA, rețele neuronale și logică fuzzy. Aceste trei metode sunt comparate, metoda bazată pe logică fuzzy prezentând o eroare apropiată de celelalte metode.

În [63], autorii realizează un set de teste pe un număr de 95 de baterii Li-Co, încărcându-le la curent constant de 0.5 C și descărcându-le cu diferiți curenți de descărcare. Autorii folosesc 3 parametri pentru a genera mulțimile fuzzy iar funcțiile de apartenență sunt de forma distribuției normale. Erorile de estimare variază între 1.4% și 9.2% dovedind-se că logica fuzzy poate fi o metodă ce se pretează pentru estimarea SOH.

O altă abordare bazată pe logică fuzzy este prezentată în [64]. Rezistența în curent continuu este folosită ca parametru, fiind măsurată în faza de încărcare.

Autorii demonstrează existența unei relații între rezistență și capacitatea bateriei. După calculul rezistenței, se definesc 4 funcții de apartenență care delimitează domeniul intrărilor. Funcțiile de apartenență definesc 4 limite: baterie sănătoasă, baterie acceptabilă, baterie slabă și baterie degradată. Valoarea actuală a capacității de face prin intermediul relației:

$$C_A = \frac{\sum_{i=1}^4 \mu_i O_i}{\sum_{i=1}^4 \mu_i} \quad (27)$$

în care C_A este capacitatea actuală estimate, μ_i este puterea de activare (grad de îndeplinire) al regulii i , iar O_i este puterea de activare a regulii de ieșire. Este calculată capacitatea actuală a mai multă baterii având SoH în intervalul 100% - 20% folosind metoda propusă. Eroarea de estimare se situează sub 5%. Autorii arată că metoda propusă este mult mai bună decât regresia liniară a cărei eroare de estimare ajunge și la 10%.

În [65] și [79] autorii pornesc de la un model dublu exponențial de forma:

$$y_{fit} = a_0 + a_1 e^{-\left(\frac{x}{a_1}\right)^{\beta_1}} + a_2 e^{-\left(\frac{x}{a_2}\right)^{\beta_2}} \quad (28)$$

Parametrii funcției sunt estimați folosind logica fuzzy, generând erori de estimare în intervalul 5%-10%.

3.1.6. Vectori suport

Constituie una dintre cele mai populare metode de estimate pentru SOH a bateriei în varianta neliniară.

Noțiunile de bază a SVM sunt prezentate în detaliu în [55] și [66]. Având un set de date de antrenare, notat prin $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \subset R^n \times R$ - în care R^n este spațiul datelor de intrare x_i , iar datele țintă sunt y_i , scopul este să se determine o funcție $f(x)$ care să aproximeze datele țintă cu o deviație maximă ϵ , pentru toate datele de antrenare. Această funcție are următoarea formă:

$$f(x) = \langle w, x \rangle + b \quad (29)$$

cu $w \in R^n$, $b \in R$ și $\langle \cdot, \cdot \rangle$ fiind produsul scalar în R^n . Există însă situații când această funcție nu există. Pentru a rezolva această problemă se introduc variabilele suplimentare ξ și ξ , care odată introduse, oferă posibilitatea definirii unui interval pentru eroarea de măsurare. În acest caz, problema se rezumă la cea de optimizare duală.

Problema optimizării duale se rezolvă folosind tehnici de programare pătratică care presupun aplicarea unei transformate neliniare intrărilor, transformată ce translatează intrările într-un spațiu multidimensional. În acest caz, funcția devine:

$$f(x) = \sum_{k=1}^K (a_k^* - a_k) K(x(k), x) + b \quad (30)$$

în care a_k^*, a_k sunt variabilele duale obținute prin aplicarea Lagrangianului relativ la (w, b, ξ, ξ^*) , iar K este funcția nucleu (funcție de mapare) având forma:

$$K(x(k), x(m)) = \langle \Phi(x(k)), \Phi(x(m)) \rangle \quad (31)$$

în care Φ reprezintă transformata neliniară.

Algoritmul RVM [68], [69], reprezintă forma Bayesiană a SVM și diferă de acesta prin introducerea unei interpretări probabilistice ale ieșirilor. Predicția ieșirilor are următoarea formă:

$$t = y(x) + \varepsilon_n \quad (32)$$

în care t este ținta pentru predicție, $y(x)$ este funcția ce translatează datele de intrare în cele țintă (de ieșire) conform SVM, iar ε_n exprimă zgomotul procesului.

După aplicarea legii lui Bayes, rezultă o funcție de distribuție posterioară:

$$p(w|t, a, \sigma^2) = \frac{p(t|w, \sigma^2)p(w, a)}{p(t|a, \sigma^2)} \quad (33)$$

în care w este vectorul ponderilor, a este vectorul hiperparametrilor folosit pentru controlul deviației ponderilor, σ este varianta, și p este funcția de distribuție posterioară.

Noile predicții se calculează prin integrarea ponderilor și calcularea probabilității marginalia ale hiperparametrilor:

$$\begin{aligned} p(t|a, \sigma^2) &= \int p(t|w, \sigma^2)p(w|a)dw \\ &= (2\pi)^{N/2} |B^{-1} + \Phi A^{-1} \Phi^T|^{-1/2} \times \exp\left(-\frac{1}{2} t^T (B^{-1} + \Phi A^{-1} \Phi^T)^{-1} t\right) \end{aligned} \quad (34)$$

în care $\mathbf{A} = \text{diag}(a_1, \dots, a_{N+1})$, și $\mathbf{B} = \sigma^2 \mathbf{I}$, iar Φ este matricea funcției nucleu, obținută printr-un set de date de antrenare.

Cele două formule de estimare pot fi aplicate seturilor de date de antrenare care conțin parametrii ai bateriei cum ar fi capacitatea.

Algoritmi de tip SVM sunt prezentați în [56], [66]-[72]. Ca o caracteristică generală, acești algoritmi rulează pe seturi extensive de date de antrenare obținute prin ciclarea bateriilor. Variante online cu predicții în timp real solicită resurse computaționale ridicate și de cele mai multe ori sunt prezentate ca simulări în Matlab.

În [56], seturile de date pentru construcția vectorilor sunt obținute prin teste îndelungate de îmbătrânire a bateriei. SVM este comparat cu UKF, prezentând erori de predicție asemănătoare. Dacă se cunoaște capacitatea inițială a bateriei, eroarea de predicție este de 1%. Fără această informație, eroarea poate crește la 20%.

În [69], autorii aplică SVM pe seturi de date rezultate din spectroscopii ale impedanței bateriei. Modelul estimează degradarea capacității bateriei precum și modificarea rezistenței interne ale acesteia, care sunt intrări pentru calcularea SOH

și RUL. SVM prezintă o performanță mai mare decât modelul Markov cu stări invizibile, cu o eroare de estimare maximă de 2%.

În [70], algoritmi SVM sunt aplicați pe seturi de date de baterii puse la dispoziție de NASA. Două variante sunt prezentate: online – în timpul ciclurilor de încărcare/descărcare și cea combinată cu analize offline. Erorile medii absolute de estimare este 0.02 în cazul variantei combinate și 0.03 în cazul variantei online.

O variantă a SVM aplicată datelor obținute din teste de durabilitate la bateriile vehiculelor hibride este prezentată în [71]. Vectorii sunt corelați cu valoarea curentului de descărcare pentru a spori performanța algoritmilor.

În [72] SVM este aplicat pentru aproximarea curbelor capacității bateriei obținute prin metoda capacității incrementale. Autorii arată cum se poate aplica această metodă pentru baterii de tip litiu-polimer. Metoda se bazează pe actualizarea parametrilor în funcție de condițiile curente ale bateriei. Eroarea de predicție se situează în jurul de 1%.

Autorii din [67] și [68] folosesc RVM cu setul de date de intrare oferite de NASA. Atenția este îndreptată pe comparația cu SVM, dovedindu-se erori mai mici pentru RVM, sub 0.6%. Cel din urmă articol abordează problema degradării bateriilor în vehicule electrice. RVM este aplicat pentru RUL obținându-se o eroare maximă de 9 cicluri încărcare/descărcare.

3.1.7. Filtre particule

Această metodă se potrivește sistemelor neliniare în care parametrii modelelor bateriei sunt necunoscuți sau aceștia se schimbă în timp. Metoda are ca rezultat funcția densitate de probabilitate bazată pe un set de puncte ce aparțin spațiului stărilor.

În [73], autorii folosesc un model electrochimic simplu pentru baterii Li-Ion pentru care parametrii sunt identificați prin RVM. Valorile obținute în pasul anterior sunt folosite ca date inițiale pentru algoritmul bazat pe particule. Particulele sunt recalulate ulterior la fiecare iterație.

În fig. 22 sunt prezentate 2 rezultate tipice pentru filtrele bazate pe particule, funcțiile densitate probabilistică pentru RUL. Se poate observa că unul dintre avantajele folosirii particulelor este că generează o distribuție probabilistică în timp, și nu se bazează doar pe un punct/dată. Acest lucru are ca și consecință reducerea incertitudinilor la nivel de parametri ai modelului precum și cel al măsurătorilor.

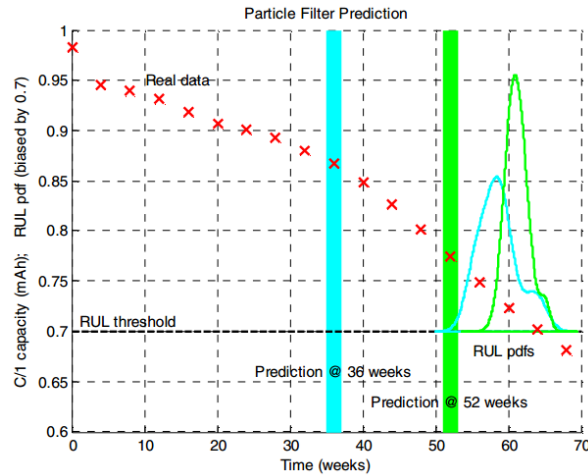


Fig. 22. Rezultatele predicției folosind filtru de particule [73]

În [74], filtrele bazate pe particule sunt folosite pentru estimarea SOC și SOH al bateriilor de tip Li-fosfat (LiFePO_4). Autorii folosesc o metodă bazată pur pe datele de intrare fără a folosi un model electric al bateriei, parametrii folosiți fiind doar OCV și curentul de încărcare/descărcare. Pasul de reeșantionare al PF, denumit și reeșantionare cu varianță redusă, constă în următoarea regulă: când se generează un nou set de eșantioane, eșantioanele vechi cu ponderi mari sunt înmulțite, pe când cele vechi cu ponderi scăzute sunt eliminate din calcul.

Autorii au validat soluția în două domenii: rețele fotovoltaice pentru consum casnic și vehicule electrice. Rezultatele nu sunt prezentate în cel mai mare amănunt atenția fiind îndreptată spre eroarea medie absolută care este în jurul a 2%.

Autorii din [75] demonstrează faptul că FP este mult mai precis decât metodele bazate pe regresie statistică, comparând erorile de predicție și dimensiunea funcției de distribuție probabilistică. În plus, este prezentat și un avantaj al FP și anume că timpul până la generarea primei predicții este mult mai scurt comparativ cu celelalte metode.

Aceiași autori prezintă în [76] o îmbunătățire a algoritmilor bazați pe FP. Ei au observat că atunci când spațiul stărilor modelului este definit prin vectori de mari dimensiuni, procesul de reeșantionare nu poate reduce varianta erorilor particulelor. Ei propun să înlocuiască acest spațiu de stări cu cel calculat bazat pe metoda Rao-Blackwellized (FPRB). Se demonstrează că FPRB prezintă erori mult mai mici iar funcția de distribuție este mult mai compactă rezultând o predicție mult mai bună.

În [77], autorii propun folosirea a două modele analitice ca intrări pentru FP. Mai precis, aceștia folosesc FP pentru a estima parametri modelului matematic polinomial și cel exponențial. Această soluție poate fi implementată într-un sistem de management al bateriilor cu predicție în timp-real la fiecare ciclu de încărcare/descărcare. O îmbunătățire a acestei soluții este prezentată în [78], în care autorii introduc o nouă abordare în modelarea capacității bateriei. Este o combinație dintre cele două modele anterioare, rezultând o mai bună precizie de estimare.

Filtrele bazate pe particule pot fi folosite ca un mecanism auxiliar pentru predicția RUL, așa cum este prezentat în [79]. Autorii prezintă o metodă complexă care se bazează pe modelul Verhulst. Pentru optimizare se folosește o nouă metodă, prin care se optimizează șiruri de particule. FP este folosit pentru a compensa erorile de predicție prin ajustarea modelului Verhulst.

O soluție originală este prezentată de autori în [79] și [80]. Autorii folosesc un model matematic simplu cu doi termeni exponențiali, pentru a facilita și implementarea într-un sistem de management al bateriei real. Ei folosesc metoda Bayesiană Monte Carlo, similară cu FP, în care rezultatul este tot o funcție de distribuție al probabilității:

$$P(X_k|Q_{0:k}) \approx \sum_{i=1}^N \omega_k^i \delta(X_k - X_k^i) \quad (35)$$

în care X_k^i este un set independent de eșantioane din P , ω_k^i ponderea fiecărui eșantion; $\delta(\cdot)$ funcția impuls Dirac. Reeșantionarea și recalcularea ponderilor se face într-un mod diferit de cel clasic FP. Pentru estimarea valorilor inițiale ale bateriei se folosește metoda Dempster-Shafer, în primii n cicli de încărcare/descărcare. BMC este folosit pentru a actualiza parametrii modelului la fiecare ciclu și totodată actualizând SOC și RUL.

În [80] FP este prezentat în comparație cu EKF, scoțându-se în evidență eroarea de estimare a FP care este în jurul de 1.1%, față de EKF unde poate ajunge și la 8.6%. În [81], autorii compară eroarea de predicție a metodei BMC folosind două metode de calcul al parametrilor diferite: DST și metoda mediană. Eroarea de predicție este de 2.1% pentru prima metodă de calcul, respectiv 8.3% pentru cea din urmă.

În [82] autorii prezintă o modificare a FP, precizând și dezavantajele metodei clasice: degenerarea particulelor. Ei propun o soluție pentru a evita acest lucru și anume utilizarea unui filtru Kalman U pentru a genera distribuția particulelor, urmând să se folosească pașii normali de reeșantionare și calcul al ponderilor din FP. Sunt prezentate o serie de teste din care rezultă că metoda propusă asigură o eroare de estimare de sub 5% pe când soluția clasică atinge o valoare a erorii de 7%.

O altă variantă a FP este prezentată în [83] pentru estimarea SOH și RUL. Această metodă își propune să reducă dezavantajele celorlalte metode prezentate anterior: FP clasic, RBFP și FPU. Printre acestea se numără: fenomenul de împușinare a eșantioanelor, lipsa acurateței de determinare a funcției densității de probabilitate. Metoda propusă transformă particulele ce au fost valori ale ponderilor foarte mari, în valori ale ponderilor foarte mici în așa fel încât să urmeze cât mai fidel partea posterioară a densității de probabilitate. Figura 9. prezintă acest algoritm.

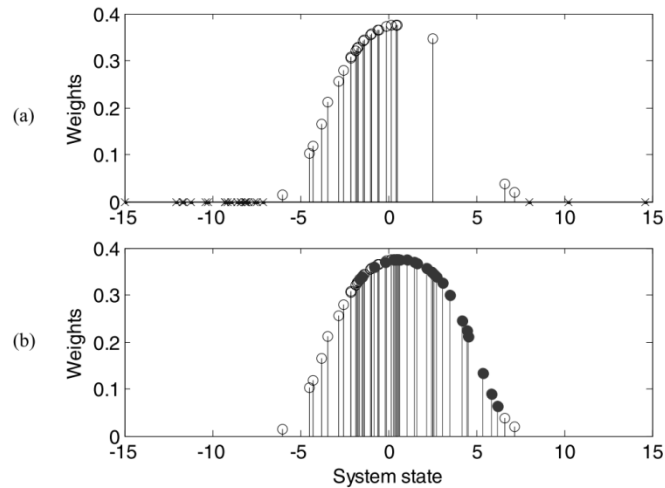


Fig. 23. Transformare MPF a funcției de distribuție de probabilitate posterioară

În [84], [86], [87] sunt prezentate variații ale metodei FP implementate în sisteme încorporate și simulate în platforme dezvoltate în Matlab. Autorii se axează pe estimarea RUL precum și detecția și prevenirea erorilor de funcționare a algoritmilor.

3.1.8. Alte metode

O nouă metodă pentru estimarea SoH și RUL ce poate fi implementată în sisteme încorporate cu resurse limitate este prezentată în [5]. Estimarea SoH se face ținând cont de SoC iar metoda de predicție este una bazată pe regresie în sensul celor mai mici pătrate.

În [88] autorii folosesc câmpul magnetic pentru a determina dacă o baterie este degradată sau nu. Sunt folosite două bobine, prima pentru a genera câmpul magnetic, iar cea de-a doua pentru măsurarea variației câmpului magnetic datorat concentrației de protoni. Se demonstrează existența unei relații între SoH și variația câmpului magnetic măsurat o dată cu degradarea bateriei.

O combinație între estimarea bazată pe cele mai mici pătrate și cea prin entropia de eșantionare este prezentată în [89]. Autorii folosesc metoda entropiei de eșantionare pentru a modela capacitatea bateriilor Li-Ion folosind teste extensive de laborator. Se folosește o funcție polinomială de ordin 3 pentru a reprezenta corespondența în valoarea capacității bateriei și valoarea entropiei pentru fiecare temperatură.

În [90] este descrisă metoda aproximării entropiei. Aceasta este o variantă a metodei entropiei de eșantionare folosită pentru estimarea SoH la baterii de plumb. Această metodă constă în calcularea funcției $ApEn(m, r, N)$ pentru un set de date $x(i) = x(1), x(2), x(3), \dots, x(N)$, cu N , reprezentând numărul total de puncte, m lungimea subsetului de puncte pentru care rulează algoritmul, r este toleranța – considerată $0,2DS$ unde DS este deviația standard al setului de date:

$$DS = \sqrt{\frac{1}{N-1} \sum_{i=1}^N \left[x(i) - \frac{1}{N} \sum_{i=1}^N x(i) \right]^2} \quad (36)$$

Funcția $ApEn$ este calculată folosind relațiile:

$$\begin{aligned} ApEn(m, r, N) &= \varphi^m(r) - \varphi^{m+1}(r) \\ \varphi^m(r) &= \frac{1}{N-m+1} \sum_{i=1}^N \ln \left(\frac{V^m(i)}{N-m+1} \right) \\ V^m(i) &= \text{No.of } d[X(i), X(j)] \leq r \end{aligned} \quad (37)$$

cu d fiind distanța între vectorii (diferența absolută între elementele scalare din vectori):

$$\begin{aligned} X(i) &= [x(i), x(i+1), \dots, x(i+m-1)], \quad i = 1, N-m+1 \\ X(j) &= [x(j), x(j+1), \dots, x(j+m-1)], \quad j = 1, N-m+1 \end{aligned} \quad (38)$$

Autorii din [91] folosesc un model cu stări neobservabile pentru estimarea SOC și SOH a bateriilor de tip Li-Ion. Setul de ecuații al modelului este determinat prin folosirea unui model electric complex alcătuit din două grupuri RC. În plus se prezintă un model pentru auto-descărcarea bateriei. Estimatorul are următoarea formă:

$$\xi = A\xi + BI_B + D\phi(V_{SOC}, I_B) \quad (39)$$

în care A , B și D sunt matricile de stare și de ieșire, ξ este vectorul de stări, și ϕ descrie neliniaritățile de estimare. Bazat pe ecuația stărilor se poate calcula rezistența internă R_0 a bateriei și se folosește următoarea formulă pentru calcularea SOH:

$$SOH = \frac{R_{0,EOF} - R_0}{R_{0,EOF} - R_{0,NEW}} \times 100 \quad (40)$$

în care R_0 este rezistența internă curentă a bateriei, $R_{0,EOF}$ este rezistența internă a bateriei când bateria este considerată inutilizabilă, iar $R_{0,NEW}$ este rezistența internă a bateriei când bateria este nouă.

O metodă bazată pe funcția densitate de probabilitate este prezentată în [90]. Această metodă este combinată cu analiza incrementală a capacității bateriei pentru a determina evoluția SOH. Se folosesc următoarele serii pentru a calcula funcția de densitate:

$$\begin{cases} V_{d,k} = V_0 + k \cdot \delta V, \quad k = 0, 1, 2, \dots \\ Q_{d,n} = Q_0 + n \cdot dQ = n \cdot I \cdot t, \quad n = 0, 1, 2, \dots \end{cases} \quad (41)$$

unde $V_{d,k}$ este tensiunea de ieșire a bateriei, d convenția de notație pentru termenul digital, k numărul eșantionului, și $Q_{d,k}$ este capacitatea bateriei obținută prin

integrare și care corespunde cu $V_{d,k}$. Valorile seriilor sunt calculate urmând multiple teste de încărcare/descărcare.

O metodă derivată din cea prezentată anterior și care folosește două funcții de densitate de probabilitate este descrisă în [92], în cadrul unui model Gaussian adaptiv. Prima funcție densitate este folosită pentru caracterizarea seturilor de date din istoric, iar cea de-a doua pentru caracterizarea setului de date curent. Parametrul bateriei folosit pentru estimare este capacitatea bateriei.

În [94] autorii propun regresia funcțională gaussiană pentru estimarea SoH. Capacitatea bateriei este monitorizată pentru a determina evoluția SoH. Un proces de tip Gaussian este definit ca un set de variabile aleatoare $\{f(x_i) | x_i \in X\}$, în care x reprezintă spațiul intrărilor (cicluri de încărcare/descărcare), și funcțiile mediană și covariație:

$$\begin{aligned} m(x) &= E(f(x)) \\ k(x_i, x_j) &= E[(f(x_j) - m(x_j)) \cdot (f(x_i) - m(x_i))] \end{aligned} \quad (42)$$

Funcția de covariație prezintă o componentă funcțională și o componentă ce modelează zgomotul, considerat gaussian. Flexibilitatea algoritmului se poate mări prin introducerea de parametri adiționali prin folosirea funcției polinomiale de ordin 2 pe post de funcție mediană. Erorile de estimare se reduc substanțial în acest caz. Algoritmul necesită un număr ridicat de date de antrenare pentru a atinge performanța sporită, autorii folosesc un minim de 100 de cicluri.

Estimarea RUL prin folosirea unui proces Wiener este propusă în [95]. Funcția de degradare a RUL este exprimată prin următoarea formulă:

$$Y(t) = X(t) + \varepsilon = \lambda t + \sigma_B B(t) + \varepsilon \quad (43)$$

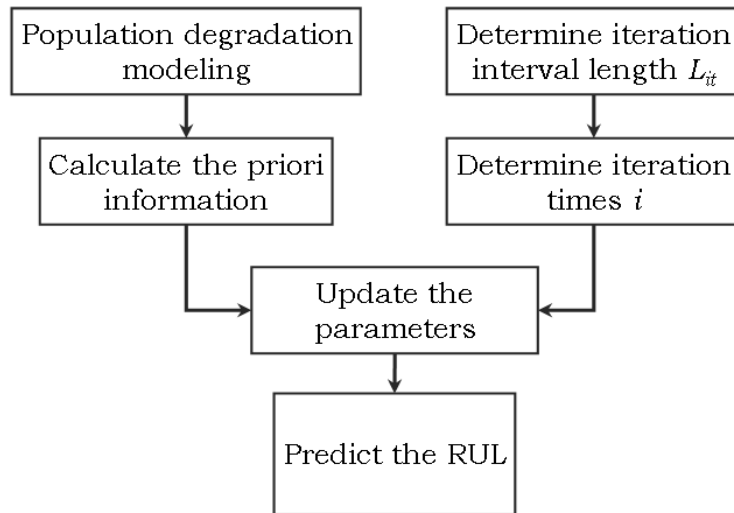


Fig. 24. Algoritm de estimare RUL propus în [87]

În [96], autorii propun o soluție de estimare a SOH bazată pe modelul autoregresiv optimizat:

$$\begin{cases} v_i^{k+1} = w \cdot v_i^k + c_1(pbest_i - x_i^k) + c_2(gbest^k - x_i^k) \\ x_i^{k+1} = x_i^k + d \cdot v_i^{k+1} \end{cases} \quad (44)$$

în care, prima ecuație reprezintă actualizarea vitezei particulelor, v_i^{k+1} este viteza nouă a particulei i , w ponderea inerției, v_i^k este viteza precedentă a particulei i , c_1 și c_2 sunt parametrii de accelerare, d este un parametru de ajustare, x_i^k este locația particulei i în iterația k , x_i^{k+1} este locația particulei i în iterația $k+1$, $pbest_i$ este cea mai bună locație individuală pe care o poate avea particula i , și $gbest$ este cea mai bună locație pe care o pot avea particulele ca grup în spațiul de soluții.

În [97] o rețea neuronală este folosită pentru modelarea proceselor electrochimice ale bateriei. Aceasta are funcția de activare pentru fiecare neuron în forma gaussiană:

$$i(r_k) = G(\|r_k - t_i\|) = \exp\left(-\frac{\|r_k - t_i\|^2}{\sigma_i^2}\right), \quad i = 1..M \quad (45)$$

unde, $r_k = [V_k \ I_k \ SoC_k]^T$ reprezintă vectorul de intrare pentru rețeaua neuronală la momentul k , t_i și σ_i sunt centrul și deviația standard a funcției lui Gauss, M este numărul de neuroni din nivelul ascuns. Rețeaua neuronală are ca ieșire tensiunea la bornele bateriei la momentul $(k+1)$. SOH este determinat folosind curve Voltaj – capacitate. Pentru a obține rezultate bune este nevoie de o antrenare cu un set consistent de date.

În [90] autorii folosesc o rețea neuronală pentru a estima SOH al bateriei. Parametrul bateriei pe care se bazează estimarea este rezistența internă a acesteia. Rețeaua neuronală este împărțită într-o subrețea una pentru estimarea SOC și cealaltă pentru estimarea parametrilor R-C al modelului electric Randles.

O variantă probabilistă de rețele neuronale sunt folosite în [93]. Acest tip de rețea are avantajul că prezintă o viteză de învățare ridicată, iar datele de antrenare se pot aplica direct fără a fi nevoie de iterații.

Abordări ce se bazează pe teoria Bayesiană sunt prezentate în [93] și [92]. Estimarea RUL se bazează pe predicția curbelor de capacitate ale bateriei. Predicția se bazează pe analize offline și calcule a priori pentru a accelera procesul de estimare.

3.2. Evaluarea comparativă a metodelor existente de estimare a SOH/RUL

Datorită multitudinii metodelor de estimare a stării de degradare a bateriilor și complexitatea acestora – fiecare metodă are particularitățile sale – este foarte greu de comparat aceste metode între ele în lipsa unui set de criterii bine definit.

Am propus următorul set de criterii care facilitează evaluarea comparativă a metodelor:

- Chimia bateriei – există metode specifice care se aplică tuturor tipurilor de chimie, precum există și metode aplicabile doar unui anumit tip

- Complexitatea computațională – acest criteriu definește tipurile de operații prin care sunt implementate metodele care pot să varieze de la cele mai simple, funcții polinomiale de ordin 2, până la cele mai complexe care pot fi operații matriciale, funcții trigonometrice, diferențiale, logaritmice, exponențiale.
- Modul de procesare a datelor – există metode care se aplică datelor primite în timp real (online), precum și metode care se aplică datelor obținute printr-o multitudine de teste de laborator (offline).
- Parametrul estimat: există metode care estimează SoH, sau RUL, sau și SoH și RUL.
- Timpul de procesare pentru prima estimare: timpul de rulare a metodei pe platforma de procesare specificată
- Precizia estimării: este un parametru ce definește cât de precisă este estimarea, este definit prin metrica definită de fiecare autor în parte (unii au optat pentru eroare absolută, alți autori au optat pentru eroarea medie absolută procentuală, etc.)

În continuare am realizat un tabel în care am evaluat toate metodele prezentate la capitolul anterior prin intermediul setului de criterii definit mai sus:

Tabel 2. Evaluarea metodelor de estimare a stării de degradare a bateriilor

Metodă	Ref	Chimia Bateriei	Complexitate computațională	Modul de procesare a datelor	SoH/ RUL estim.	Timpul de procesare pentru prima estimare	Precizia estimării
Coulomb Counting	[47]	Li-Ion	Funcții și operații liniare	Online	SoH	N/A	~ 9% în ciclul 21; ~ 1% după al 8-lea ciclu
	[48]	LiFePO4	Funcții și operații liniare – metoda inițială ; Operații matriciale (înmulțire, transpusa), Funcții exponențiale (versiunea modificată)	Online	SoH	În combinație cu filtrarea Kalman:: 2000 sec	între +/-3%
OCV	[4]	Li-Ion	Operații liniare, funcții exponențiale	Online cu parametri determinați offline	SoH	N/A	Eroare de estimare: < 1%
	[22]	Li-Ion	Funcții polinomiale cu termeni exponențiali	Parametri identificați offline	SoH	N/A	< 1%
Filtre Kalman	[59]	Aplicabil tuturor tipurilor de chimii; demonstrat pentru NiMH	Operații matriciale (înmulțire, transpusa), funcții logaritmice	Offline	SoH	N/A	Max. 8.3%

[60][60]	Li-Ion	operații matriciale (înmulțiri, transpusă), funcția radical	Offline	SoH	N/A	Eroare de estimare se situează în intervalul: +/-5%
[55]	Li-Ion	operații matriciale (înmulțiri, transpusă), funcții polinomiale (de ordin 3)	Online, bazat pe date offline	SoH	N/A	RMS în intervalul 2.2% și 2.9%
[53]	Li-Ion	operații matriciale (înmulțiri, transpusă)	Online	SoH	N/A	Eroarea de estimare +/-5%
[50]	Li-Ion	operații matriciale (înmulțiri, transpusă), funcții exponențiale	Online	SoH	Estimarea se bazează pe date luate pe fereaștră de 30 minute	Eroare de estimare a parametrilor modelului 1%; eroare de estimare a SoH < 4%
[56]	Li-Ion	operații matriciale (înmulțiri, transpusă), funcții exponențiale	Online	SoH	N/A	eroare de estimare: < 1%
[51]	Li-Ion	operații matriciale (înmulțiri, transpusă), funcții exponențiale	Offline	SoH	N/A	eroare de estimare: < 4%
[52]	Li-Ion	operații matriciale (înmulțiri, transpusă), funcții exponențiale	Online cu parametri obținuți offline	SoH	N/A	eroare de estimare: < 1%
[54]	Lead acid	operații matriciale (înmulțiri, transpusă), funcții exponențiale	Online	SoH	N/A	< 2%

	[58]	Li-Ion	operații matriciale (înmulțiri, transpusă), operații liniare	Online	SoH	Actualizarea parametrilor modelului pentru a avea o eroare acceptabilă este de 40 minute	2%
	[61]	Li-Ion	operații matriciale (înmulțiri, transpusă), funcția radical	Online	SoH	N/A	MSE în intervalul -0.6 și 0.6
Vectori suport (SVM-RVM)	[56]	Aplicabil tuturor tipurilor; Demonstrat pentru NMC (Nickel Manganese Cobalt)	Funcții exponențiale, produs vectorial (multiply and acumulate)	Offline	SoH	N/A	eroare de estimare: < 1%
	[69]	Li-Ion	Funcții exponențiale, produs vectorial (multiply and acumulate)	Offline (poate fi modificat online)	SoH and R	Specifică că este intensiv computațional	eroare de estimare ~ 2%
	[67]	Li	Funcții exponențiale, produs vectorial (multiply and acumulate), operații matriciale (înmulțiri, transpusă),	Offline	SoH	N/A	SVM RMSE între 0.47 și 1.43; RVM RMSE între $5.96 \cdot 10^{-5}$ și 0.5
	[70]	Li	Funcții exponențiale, produs vectorial (multiply and acumulate)	Online combinat cu offline	RUL	N/A	Metodă combinată: MAE 0.02; online: MAE 0.03
	[71]	Li-Ion	Funcții exponențiale, produs vectorial (multiply and acumulate)	Online, bazat pe date offline	SoH and R	N/A	MSE $8 \cdot 10^{-4}$; 1LC: MSE $0.1 \cdot 10^{-4}$; 3LC: MSE $0.02 \cdot 10^{-4}$
	[68]	Li-Ion	Funcții exponențiale, produs vectorial (multiply and acumulate), operații matriciale (înmulțiri, transpusă)	Online, bazat pe date offline	RUL	N/A	Eroare absolută de predicție după 100 de cicluri: 4 cicluri; Eroare absolută de predicție după 200 de cicluri: 2 cicluri;

	[72]	Li-Polymer	Funcții exponențiale, produs vectorial (multiply and acumulate)	Online, bazat pe date offline	SoH	Specifică că este moderat computațional	Eroare absolută de predicție: 1%
Filtru particule	[79]	Graphite anode Lithium Nickel Cobalt oxide cathode	Funcții exponențiale	Offline (regresie RVM and online (bazat pe filtru particule)	RUL	N/A	9.1% în săptămâna 32 of 64; 4.0% în săptămâna 48 of 64
	[80]	Graphite anode Lithium Nickel Cobalt oxide cathode	Funcții exponențiale, Înmulțiri în virgulă flotantă	Offline (regresie RVM) și online (bazat pe filtru particule)	RUL	N/A	3.1% în săptămâna k 48 of 64
	[81]	Li-Ion	Funcții exponențiale (modelul A), înmulțiri simple înmulțiri (model B)	Online	SoH and R	N/A	Model A: 0.4% la ciclul 550 of 780; model B: 11.5% la ciclul 550 of 780
	[82]	Li-Ion	Funcții exponențiale, Înmulțiri în virgulă flotantă	Online	RUL	N/A	Pentru celula #01: 12.1% la ciclul 566 din 849; Pentru celula #02: 1.5% la ciclul 428 din 643; Pentru celula #V4: 0.1% la ciclul 422 din 633
	[83]	Li-Ion	Funcții exponențiale, împărțiri/înmulțiri virgulă flotantă	Online	RUL	N/A	Pentru celula A4: 4.2% la ciclul 27 din 48; pentru celula A2: 1.6% la ciclul 120 din 189
	[84]	Graphite anode Lithium Cobalt oxide cathode	Funcții exponențiale, Înmulțiri în virgulă flotantă, transpoziții vectoriale	Poate fi adaptat online	SoH and R	10 ms pe procesor Intel Core i7 M60 2.67 GB și 4 GB RAM (Matlab)	2.1% la ciclul 18 din 48; 1.1% la ciclul 250 din 610
	[85]	Li-Ion	Funcții exponențiale, Înmulțiri în virgulă flotantă	Offline și online	RUL	N/A	2.0% at la ciclul 18 din 48.

	[74]	LiFePO4	Funcții trigonometrice, Înmulțiri în virgulă flotantă	Offline și online	SoH	N/A	< 2.0%,
	[85]	Graphite anode Lithium Cobalt oxide cathode	Funcții exponențiale, Înmulțiri în virgulă flotantă, transpoziții vectoriale	Offline și online	RUL	N/A	< 5%
Logică fuzzy	[62]	Primary Li Secondary NiCd and NiMH	N/A	Offline și online	SoH	N/A	între 2.0% și 7.9% pentru SoC; N/A pentru SoH
	[63]	Graphite anode Lithium Cobalt oxide cathode	Funcții exponențiale, împărțiri/înmulțiri virgulă flotantă	Online	SoH	15.6 ms, nu se specifică platforma	între 1.4% și 9.2%
	[64]	Li-Ion	Simple înmulțiri / împărțiri	Online	SoH	N/A	Max. 5%
Spectroscopia impedanței	[16]	Graphite anode Lithium Cobalt Manganese Nickel oxide cathode	Funcții exponențiale, înmulțiri în virgulă flotantă	Offline	SoH and R	N/A	medie 2.1%
	[101]	Graphite anode Lithium Cobalt Manganese Nickel oxide cathode	Funcții exponențiale, înmulțiri în virgulă flotantă	Offline	SoH and R	N/A	Max 10% (pentru partea reală a impedanței)
Regresii liniare în sensul celor mai mici pătrate	[5]	NiMH	Ecuatii liniare simple	Online	SoH and R	< 550 μ s la 14MHz pe o platforma ARM 7	Eroare de estimare: +/- 5 cicli
Câmp magnetic	[88]	SLA	Ecuatii liniare simple	Online	SoH	N/A	N/A
Entropie de eșantionare	[89]	Li-Ion	Operații vectoriale, ecuații liniare, funcții logaritmice	Online, bazat pe date offline	SoH	N/A	Eroare relativă medie 2%
Entropie de aproximare	[90]	Lead Acid	Operații vectoriale, operații matriciale, Funcții logaritmice	Online, bazat pe date offline	SoH	N/A	N/A

Modele neobservabile	[91]	Li-Ion	Operații vectoriale, operații matriciale, Funcții exponențiale	Online, bazat pe date offline	SoH	N/A	Eroare absolută: > 21.2% în primele 681 sec, 6.7% după 1000 sec, 3% după 2000 sec, 0.6 % după 3000 sec, ~ 0% după 4000 sec, Doar puțini cicli au fost luați în considerare
PDF	[92]	LiMn2O4 LiFePO4	Funcții liniare, Funcții diferențiale	Online, bazat pe date offline	SoH	N/A	Eroare de estimare sub 2%
GPR/GPFR	[93]	Li-Ion	Operații matriciale, Funcții diferențiale, Funcții exponențiale	Offline, poate fi modificată pentru online	SoH	N/A	MAPE: < 0.5% RMSE: 1.5 ÷ 6
Procese Wiener	[94]	Li-Ion	Expresii logaritmice și exponențiale, operații vectoriale și matriciale	Online, bazat pe date offline	RUL	N/A	MSE: < 1 după ciclul 67
Metodă AR cu PSO	[95]	Li-Ion	Operații liniare	Online, cu date minimale de antrenare	RUL	< 2 sec. pentru prima predicție, ~ 2 sec pentru următoarele predicții având 190 de eșantioane de intrare, pe un procesor Intel Core E5800, 3Ghz, 2GB RAM	Eroare de estimare a ciclilor rămași: < 30 ciclii pentru primii 120 ciclui, < 2 cycles pentru ciclui 120 - 200
Rețele neuronale	[97]	VRLA	Funcții exponențiale, operații matriciale și vectoriale	Online	SoH	N/A	Eroare de estimare max. 2%

	[51]	Li-Ion	Funcții exponențiale, operații matriciale și vectoriale	Online, bazat pe date offline	SoH	N/A	Eroare de estimare < 0.5%
	[98]	Li-Ion	Funcții exponențiale, operații matriciale și vectoriale	Online, bazat pe date offline	SoH	N/A	Eroare medie of 0.28% for a pentru un nr. de 2000 eșantioane de antrenare
Abordări Bayes	[99]	Li-Ion	operații vectoriale, Funcții exponențiale	Online	RUL	N/A	Eroare de estimare sub 2%
	[100]	Li-Ion	operații vectoriale, Funcții exponențiale	Online	RUL	N/A	Eroare de estimare între 0.3% și 10%

3.3. Concluzii

Tabelul 2 sumarizează o comparație a metodelor de estimare a stării de degradare a bateriilor regăsite în literatură ținând cont de 5 criterii de evaluare: chimia bateriei, complexitatea computațională, timpul de procesare, eroarea de estimare și modelul de procesare al datelor.

În general cam toate metodele chiar dacă au fost definite pentru o chimie de baterii, se pot adapta noilor sau diferitelor chimii de baterii o dată ce acestea sunt produse.

În ceea ce privește complexitatea computațională metodele bazate pe filtru de particule, filtru Kalman, vectori suport, Bayes, rețele neuronale recurente folosesc operații matriciale și funcții matematice complexe în opoziție cu metodele simple OCV, regresii polinomiale, logica fuzzy. Deși eroarea de estimare a metodelor complexe este mult mai mică, acestea rămân de cele mai multe ori la stadiu de concept, fiind aproape imposibil de implementat într-un BMS real.

Metodele simple sunt cele care se regăsesc des implementate în sisteme de management reale, doar că eroarea de estimare a acestora este destul de mare. O categorie aparte o constituie rețelele neuronale care prezintă o complexitate medie spre mare în funcție de modelul ales. Datorită progresului tehnologic din acest domeniu și apariția procesoarelor cu hardware dedicat operațiilor rețelelor neuronale problema implementării acestora în sisteme de management reale nu mai constituie o problemă. În acest context, metodele de estimare bazate pe rețele neuronale pot prezenta erori de estimare foarte bune dacă se utilizează în mod corect seturile de date pentru tipul de baterii pentru care se vrea a face estimarea. Producerea acestor seturi de date rămâne o problemă datorită timpului și condițiilor de laborator necesare pentru o acuratețe cât mai bună.

Un alt aspect observat din analiza metodelor existente este că în general autorii s-au axat pe a prezenta erorile și modul de funcționare a metodelor în condiții de laborator (temperatură 25 de grade Celsius) și curent de descărcare constant. Aceste condiții nu sunt apropiate de condițiile de utilizare obișnuită când curentul de descărcare este unul variabil, iar temperatura este de asemenea diferită de cea de laborator.

4. METODĂ DE EVALUARE A STĂRII DE DEGRADARE A BATERIILOR BAZATE PE REGRESIE POLINOMIALĂ

4.1. Descrierea metodei

Această metodă a fost dezvoltată în laboratorul DSPLabs din cadrul universității Politehnica din Timișoara. În parte, cercetarea a fost finanțată de către Ministerul Educației și Cercetării prin grantul PNCDI II ID-22/2007-2010, la care am colaborat cu Gabriel N. Cârstoiu.

În cadrul sistemului robotic dezvoltat a existat nevoia predicției stării de degradare a bateriilor, scop urmărit prin implementarea acestei metode.

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

Regresia polinomială are următoarea formă:

$$C_k = ak^2 + bk + c, a < 0 \quad (46)$$

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

$$\begin{cases} a \sum_k k^2 + b \sum_k k + cn = \sum_k C_k \\ a \sum_k k^3 + b \sum_k k^2 + c \sum_k k = \sum_k k C_k \\ a \sum_k k^4 + b \sum_k k^3 + c \sum_k k^2 = \sum_k k^2 C_k \end{cases} \quad . k = \overline{1, n}, n \geq 3 \quad (47)$$

Acest sistem se poate rezolva prin intermediul determinanților:

$$\Delta = \begin{vmatrix} \sum_k k^2 & \sum_k k & n \\ \sum_k k^3 & \sum_k k^2 & \sum_k k \\ \sum_k k^4 & \sum_k k^3 & \sum_k k^2 \end{vmatrix} \quad (48)$$

$$\Delta_a = \begin{vmatrix} \sum_k C_k & \sum_k k & n \\ \sum_k kC_k & \sum_k k^2 & \sum_k k \\ \sum_k k^2C_k & \sum_k k^3 & \sum_k k^2 \end{vmatrix} \quad (49)$$

$$\Delta_b = \begin{vmatrix} \sum_k k^2 & \sum_k C_k & n \\ \sum_k k^3 & \sum_k kC_k & \sum_k k \\ \sum_k k^4 & \sum_k k^2C_k & \sum_k k^2 \end{vmatrix} \quad (50)$$

$$\Delta_c = \begin{vmatrix} \sum_k k^2 & \sum_k k & \sum_k C_k \\ \sum_k k^3 & \sum_k k^2 & \sum_k kC_k \\ \sum_k k^4 & \sum_k k^3 & \sum_k k^2C_k \end{vmatrix} \quad (51)$$

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

$$a = \frac{\Delta_a}{\Delta}, \quad b = \frac{\Delta_b}{\Delta}, \quad c = \frac{\Delta_c}{\Delta}. \quad (52)$$

Pentru calcularea mai simplă a determinanților 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:

$$S_{k+1} = S_k + (k + 1), S_{(k+1)^2} = S_{k^2} + (k + 1)^2, \text{ etc.} \quad (53)$$

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

Calculul valorii m se reduce la rezolvarea inecuației:

$$F \cdot C_{\text{nominal}} > ak^2 + bk + c \quad (54)$$

Cum $a < 0$, m devine:

$$m = \left\lfloor \frac{-b - \sqrt{b^2 - 4ac}}{2a} \right\rfloor, \quad (55)$$

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 neliniarități, acuratețea începe să fie afectată în sens negativ.

4.2. Implementarea metodei

Pentru evaluarea metodei am recurs la implementarea acesteia pe hardware-ul aferent plăcii de management al consumului, care face parte din arhitectura unui WIT (wireless intelligent terminal), specificat în proiectul CORE-TX (Collaborative Robotic Environment – The Timișoara Experiment) [102].

Această placă de management al consumului are rol de a asigura energia electrică întregului sistem precum și monitorizarea stării de degradare a bateriei în vederea creșterii duratei de utilizare al acesteia. Versiunea prototip funcțional al plăcii de management al consumului este reprezentată în figura de mai jos.




Fig. 25. Placa de management al consumului în cadrul unui WIT

Managementul bateriei se face prin intermediul măsurării cu acuratețe ridicată a tensiunii, curentului și a temperaturii bateriei. Curentul este măsurat prin intermediul unei scheme de tip high side fig. 26, iar temperatura este măsurată cu un senzor de tip TMP101[103]. În acest tip de schemă, R_s este rezistența consumatorului (în cazul nostru celelalte plăci din sistem), I_{circ} , curentul prin circuit, R_{shunt} , rezistența șuntului. Folosind componente de înaltă precizie, implementarea asigură o rezistență bună la zgomot. Metoda folosită pentru calculul capacității este coulomb counting.

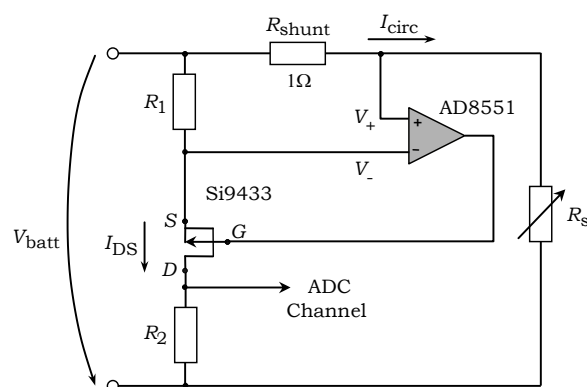


Fig. 26 Schema de tip high-side pentru măsurarea curentului

Din punct de vedere al subsistemului software, a fost aleasă o arhitectură pe nivele, în care distingem trei nivele (fig. 27):

- Managerul stării de degradare al bateriilor (nivel aplicație): asigură măsurarea, stocarea și procesarea parametrilor bateriei precum și tratarea comenzilor de management al consumului.
- Nivelul de management al taskurilor sistem: se ocupă de planificarea și execuția task-urilor hard real time, corespunzător modelului HARETICK (Hard REal-TIME Compact Kernel) [104].
- Nivelul de abstractizare hardware: conține driverele și interfețele microcontroler-ului precum și a celorlalte periferice de pe placă.

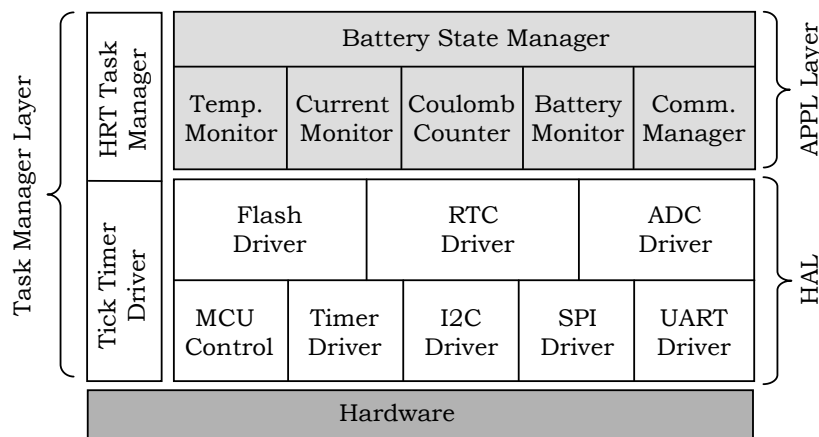


Fig. 27. Arhitectura software al plăcii de management al consumului

Software-ul care rulează predicția propriu-zisă poate fi reprezentat prin intermediul următorului pseudocod:

Codul 1. Secvența de cod pentru predicție

```

1:   while not (battery cycle completed) do
2:       wait
3:   end while
4:   increment  $n$ 
5:   if  $n \geq n_{\min}$  do
6:       Calculate  $Sum_1, Sum_2, \dots, Sum_7$  with (8)
7:       Calculate  $\Delta_1, \Delta_2, \Delta_3$ 
8:       Calculate  $\Delta$ 
9:       Calculate  $\Delta_4, \Delta_5, \Delta_a$ 
10:      Calculate  $\Delta_6, \Delta_b$ 
11:      Calculate  $\Delta_7, \Delta_c$ 
12:      // Scaling of  $\Delta, \Delta_a, \Delta_b, \Delta_c$ 
13:           $\Delta = \Delta / 128$ 
14:           $a = (\Delta_a \text{ left shifted } 20 \text{ bits}) / \Delta$ 
15:           $b = (\Delta_b / \Delta) \text{ left shifted } 20 \text{ bits}$ 

```

```
16:            $c = (\Delta_c / \Delta)$  left shifted 20 bits
17:           Solve (9) and calculate  $m$  according to (10)
18:            $n_{RUL} = m - n$ 
19:           end if
```

La fiecare pas (ciclu de descărcare al bateriei), se trece la calculul determinanților urmat de calculul parametrilor funcției de reprezentare a capacității bateriei. Ultimul pas este calcularea numărului de cicli de încărcare / descărcare a bateriei până când aceasta este considerată neutilizabilă.

Algoritmul ales este unul foarte simplu, ales pentru a asigura posibilitatea implementării acestuia în sisteme încorporate cu resurse computaționale și de memorie limitate. Chiar și așa, implementarea pe platforma de 32 biți ARM7 nu a fost lipsită de probleme:

- calculele intermediare depășesc 32 de biți - în acest caz multe din variabile au necesitat o reprezentare pe 64 de biți
- arhitectura microcontrolerului nu oferă suport nativ (hardware) pentru operații în virgulă flotantă - în acest caz am recurs la scalarea și trunchierea variabilelor la numere întregi mari.
- Calculul funcției radical, al valorii de 64 de biți a trebuit optimizată deoarece implementarea standard C oferă o implementare ineficientă din punct de vedere computațional.

5. METODĂ DE EVALUARE A STĂRII DE DEGRADARE A BATERIILOR FOLOSIND REȚELE NEURONALE RECURENTE DE TIP GRU

5.1. Descrierea metodei

Voi descrie metoda de estimare a stării de degradare a bateriilor pornind de la Fig. 28 ce prezintă structura unui sistem de management al bateriilor tipic ce folosește o metodă de estimare a stării de degradare în timp real (online).

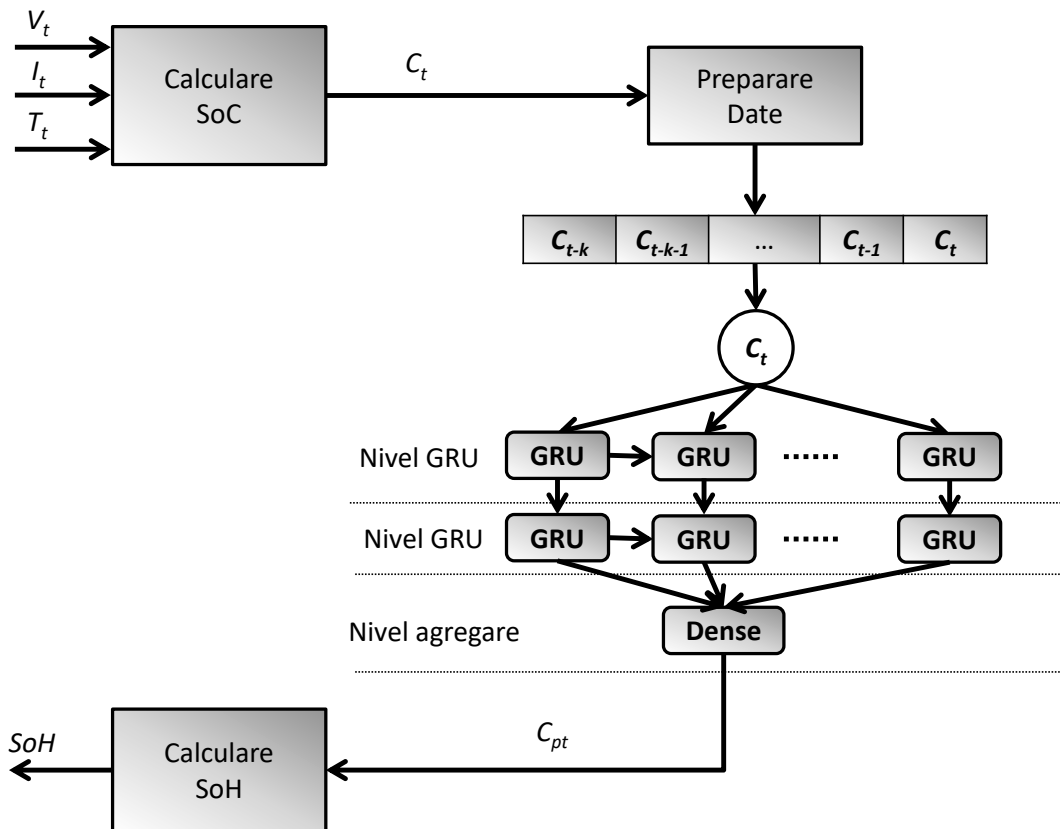


Fig. 28. Schema de principiu a metodei de estimare a stării de degradare a bateriilor bazată pe rețele neuronale de tip GRU

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,

62 5. Metodă de evaluare a stării de degradare a bateriilor folosind rețele neuronale recurente de tip GRU

reprezentate prin V_t, I_t, T_t . Acest bloc poate fi implementat prin utilizarea oricărei metode cunoscute de determinare a SoC al bateriei de la cele mai simple cum ar fi integrarea în timp a produsului curent de descărcare și tensiune la borne(cunoscută în literatură ca „Coulomb Counting”) până la cele mai complexe. Pentru lucrarea de față am folosit baze de date ce conțin deja acest parametru calculat în condiții de laborator și nu am implementat un astfel de bloc computațional, obiectivul lucrării fiind elaborarea unei metode de estimare a stării de degradare a bateriei.

- Blocul „Preparare date” – asigură pregătirea datelor și ajustarea acestora pentru prezentarea acestora la intrarea rețelei neuronale recurente. Acest stagiu de pregătire a datelor presupune următoarele operații:
 - Crearea secvenței de intrare în rețeaua neuronală. Acest lucru se realizează prin obținerea în fiecare instanță de timp (după fiecare ciclu de descărcare) a unui vector C_t ce conține valorile $C_{t-k}, C_{t-k-1}, \dots, C_{t-1}, C_t$, a capacităților pe ultimele k cicluri. De menționat este faptul că în primele k cicluri, acest bloc nu produce nici o ieșire - cu alte cuvinte nu se realizează nici o estimare a stării de degradare a bateriilor.
 - Limitarea intrărilor în valorile minime și maxime cu care a fost antrenată rețeaua. Acest lucru asigură evitarea funcționării incorecte a rețelei neuronale prin introducerea unor valori în afara intervalului cu care aceasta operează normal.
 - Normalizarea datelor de intrare în intervalul $[-1, 1]$, acest lucru fiind necesar pentru funcția de activare din nivelul ascuns.
- Rețeaua neuronală propriu-zisă. Structura rețelei va fi discutată în paragraful următor. Ieșirea rețelei neuronale este capacitatea estimată în formă normalizată.
- Blocul de calculare SoH se ocupă de transformarea capacității estimate a bateriei și calcularea procentuală a stării de degradare a bateriei conform relației:

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

Implementarea metodei de estimare a stării de degradare a bateriei se poate sumariza prin intermediul următorului pseudocod:

Codul 2. Metoda de estimare a stării de degradare a bateriei

```

1: while not (battery cycle completed) do
2:     wait
3: end while
4: determine SoC
5: Prepare data  $C_{t-k}, C_{t-k+1}, \dots, C_{t-1}, C_t$ 
6: Calculate  $C_{pt}$ 
7: Calculate  $SOH_t$ 
8: if  $C_{pt}/C_{nom} > 1$ 
9:      $SOH_t[\%] = 100\%$ 
10: else if  $C_{pt}/C_{nom} < SOH_0$ 
11:      $SOH_t[\%] = 0\%$ 
11: else
12:      $SOH_t[\%] = \left(1 - \frac{1 - \frac{C_{pt}}{C_{nom}}}{SOH_0}\right) * 100[\%]$ 
13: end if

```

5.2. Structura rețelei neuronale

Rețeaua neuronală recurentă are structura prezentată în fig. 29 Este formată din două nivele ascunse formate din celule GRU și un nivel de agregare (denumit "dense"). De notat este faptul că pentru simplitate am ales modul de reprezentare al rețelei recurente cel desfășurat (unrolled).

Pentru reprezentarea acestei rețele am folosit mediul Keras 2.4.0 împreună cu Tensorflow 2.1:

Codul 3. Reprezentarea rețelei neuronale propuse

```

model = Sequential()
model.add(GRU(nCells, activation='tanh', recurrent_activation='sigmoid', input_shape=(
    nSteps, nFeatures), implementation=1, use_bias=True, reset_after=True,
    return_sequences=True))
model.add(GRU(nCells, activation='tanh', recurrent_activation='sigmoid', input_shape=(
    nSteps, nFeatures), implementation=1, use_bias=True, reset_after=True))
model.add(Dense(1))

```

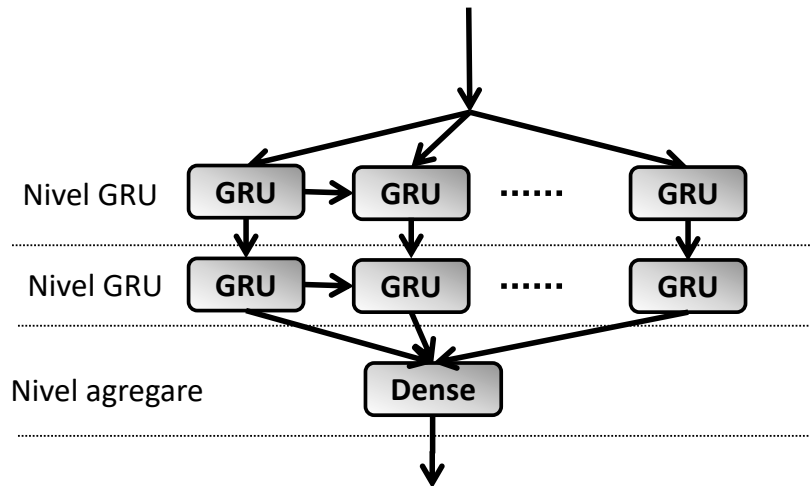


Fig. 29 Structura rețelei neuronale cu celule de tip GRU

5.3. Antrenarea rețelei neuronale

Pentru învățare am folosit un algoritm cu gradient descrescător în varianta de optimizare Adam (*adaptive moment estimation*). Acest algoritm combină avantajele introduse de algoritmul Adagrad și RMSProp în sensul că menține rata de învățare per parametru, lucru important din punct de vedere al performanței când gradientii sunt matrici rare. Ratele de învățare per parametru sunt actualizate ținând cont de media celor mai recente valori ale gradientilor.

Algoritmul salvează media mobilă exponențială a pătratului gradientilor anteriori v_t , asemenea Adadelta și RMSProp, precum și media mobilă exponențială a gradientilor anteriori m_t , asemenea algoritmului momentum.

Cele două medii mobile exponențiale se pot calcula folosind următoarele relații:

$$\begin{cases} m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \end{cases} \quad (57)$$

La inițializare și în cadrul primilor pași se poate observa că valorile m_t și v_t înclină spre valoarea 0, în special în momentul în care valorile lui β_1 și β_2 sunt apropiate de 1. Pentru a evita această situație se iau în considerare valorile corectate a celui de-al doilea momentum:

$$\begin{cases} \hat{m}_t = \frac{m_t}{1 - \beta_1^t} \\ \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \end{cases} \quad (58)$$

Folosind cele două ecuații putem obține ecuația regulii de actualizare a parametrilor:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{V}_t + \varepsilon}} \hat{m}_t \quad (59)$$

În care θ este matricea de parametri a modelului care sunt actualizați în fiecare ciclu t , η este rata de învățare, și ε este o constantă foarte mică pentru a evita împărțirea cu 0. Din punct de vedere al performanței, algoritmul Adam este destul de rapid, având un consum de memorie relativ scăzut.

5.4. Variantă modificată cu filtru treaptă

Am modificat metoda de estimare a stării de degradare a bateriilor prin introducerea unui filtru de tip treaptă. Acest filtru funcționează după cum urmează:

$$f(x_n) = \begin{cases} x_n, & x_n < x_{n-1} \\ x_{n-1}, & x_n \geq x_{n-1} \end{cases} \quad (60)$$

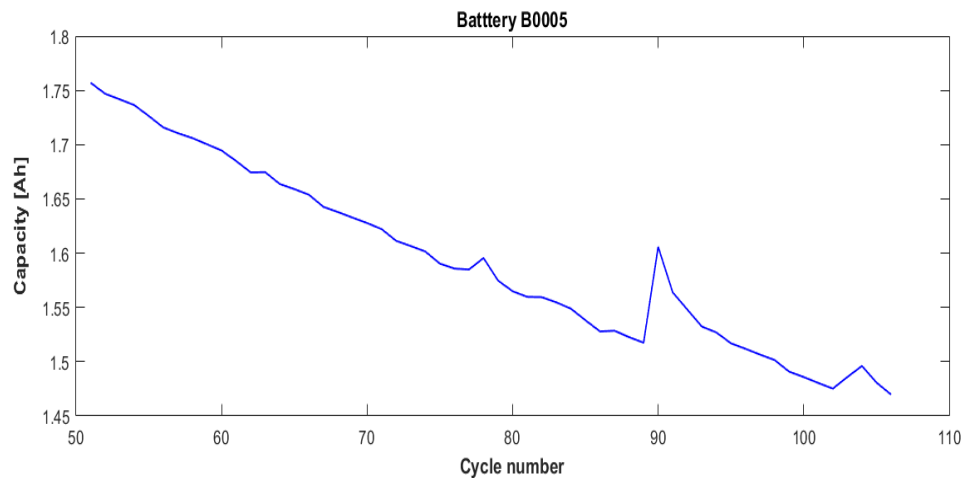


Fig. 30. Efectul de regenerare întâlnit la unele tipuri de baterii

Datorită utilizării acestui filtru se pot crește performanțele estimării, reducându-se astfel erorile de estimare. O analiză detaliată este prezentată în secțiunea de evaluare a performanței.

În figura 31 este prezentată datele aferente capacității bateriei B01 obținută prin efectuarea ciclurilor de încărcare/descărcare folosind aparatul CADEX 7400ER. Se observă că acest tip de baterie nu prezintă efect de regenerare.

66 5. Metodă de evaluare a stării de degradare a bateriilor folosind rețele neuronale recurente de tip GRU




Fig. 31. Capacitatea bateriei B01(Panasonic NCR18650A)

Metoda de estimare modificată este prezentată în figura de mai jos:

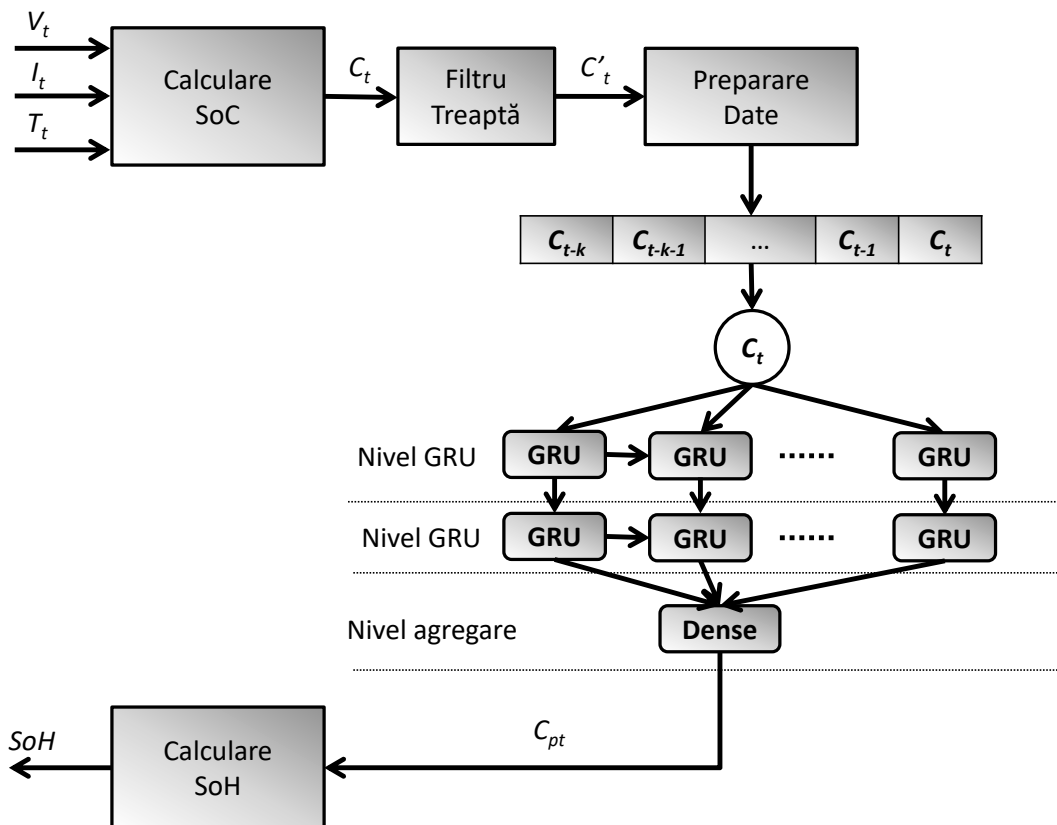


Fig. 32. Metoda de estimare modificată prin introducerea filtrului treaptă

6. SISTEM CADRU DE ANALIZĂ A PERFORMANȚELOR METODELOR DE ESTIMARE A STĂRII DE DEGRADARE A BATERIILOR BAZATE PE REȚELE NEURONALE

6.1. Obiective

Datorită multitudinii metodelor de estimare a stării de degradare a bateriilor, sarcina de a compara aceste metode este destul de grea, mai ales prin prisma implementării acestora în sisteme de management al bateriilor. Multe din metode sunt prezentate de către autori la nivel de concept acompaniat de o simulare pe calculator. În lipsa unui cadru de evaluare al acestor metode pe implementări în sisteme reale este foarte greu să se discearnă care din metode este fezabilă a fi implementată (chiar și într-un sistem comercial).

Prin teza de față propun un sistem de evaluare a metodelor de estimare a stării de degradare a bateriilor care poate fi folosit atât pentru a compara metodele la nivel de simulare pe calculator cât și compararea acestora la nivel de implementare pe diferite platforme de sisteme încorporate cunoscute.

6.2. Structura sistemului

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. Cu ajutorul particularităților pe care le pune la dispoziție mediul Keras, se pot defini o mulțime de metode de estimare. Acest nivel se adresează simulării metodei pe calculator. Este la latitudinea fiecăruia să configureze metricile de evaluare a performanțelor a metodei. În urma modelării pe calculator a metodei rezultă un set de parametri ce vor fi utilizați pentru implementarea în sisteme încorporate.
- Nivelul 2 – este nivelul de reprezentare computațional pe platforme de sisteme încorporate. Se pot alege pentru comparare mai multe biblioteci de procesare cum ar fi: PnP (Paper and Pencil), Tensorflow (pentru anumite sisteme), biblioteci matematice de algebra liniară precum OpenBlas, Blasfeo. Acest nivel este implementat în C/C++ pentru a ușura portarea pe diferite arhitecturi hardware și bineînțeles pentru a deschide calea spre optimizări computaționale acolo unde este cazul.
- Nivelul 3 – este nivelul de platformei HW pe care se dorește implementarea. Setul de platforme hardware este destul de cuprinzător și conține arhitecturi Arm de la cele mai simple (M3) până la cele mai complexe(A53).

- Nivelul 4 – este nivelul de colectare a metricilor de evaluare a performanței metodei de evaluare a stării de degradare a bateriilor în implementare reală (pe sistem încorporat). Am definit 4 metrice de evaluare a performanței: timpul de procesare, memoria utilizată, consumul de energie precum și eroarea de estimare.

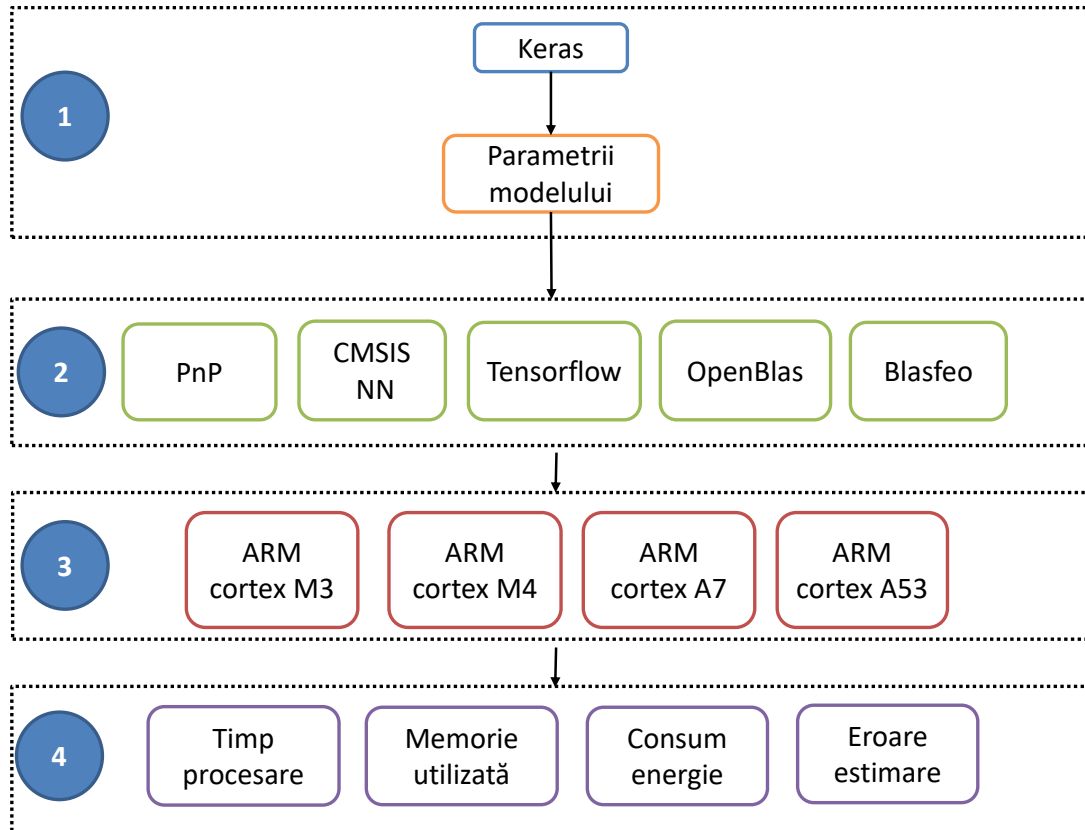


Fig. 33. Structura sistemului cadru de evaluare a performanțelor metodelor de estimare a stării de degradare a bateriilor

6.3. Criterii de evaluare și metrice de performanță

Criteriile de evaluare și metricele de performanță fac parte din nivelul 4 al sistemului cadru 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. Am considerat calcularea timpului de procesare prin următoarea formulă: Timpul de procesare = $T_f - T_i$ [ms], unde T_f - este instanța de timp

la finalul execuției estimării, T_i – este instanța de timp înainte de execuția estimării.

- Memoria utilizată – în funcție de platforma aleasă avem mai multe tipuri de memorie: flash (pentru constante), SRAM și DRAM pentru algoritmi propriu zis. Memoria utilizată este raportată în KBytes. Memoria utilizată am calculat-o cu ajutorul hărții de memorie rezultată în urma compilării pentru implementările în limbajul C/C++, iar pentru cele bazate pe limbajul Python am folosit utilitare de calcul al maximumului de memorie alocată dinamic utilizată.
- 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 încorporat. Această eroare se poate calcula folosind relația:

$$E = (V_{est} - V_{real}) / 100 [\%],$$
unde V_{est} – reprezintă valoarea estimată prin aplicarea metodei, V_{real} – reprezintă valoarea reală a capacității bateriei la ciclul de descărcare dat.

6.4. Exemplu de evaluare a performanței folosind implementarea PnP

Evaluarea performanțelor metodei folosind implementarea PnP presupune translatarea parametrilor GRU obținuți prin antrearea modelului în structura compatibilă PnP. Aceasta presupune conversia din formatul .hd5 (obținut prin antrenare în Keras) într-un format simplu C ce se poate observa în codul următor:

Codul 4. Definierea parametrilor modelului pentru implementarea PnP

```
static const float wz[] = {
    -0.6168708, ..., -0.7502499,
};
static const float wr[] = {
    -0.45586815, ..., -0.17601903,
};
static const float wh[] = {
    0.78859043, ..., -0.64399165,
};
static const float bwz[] = {
    -0.17063044, ..., 0.1079701,
};
static const float bwr[] = {
    0.25578716, ..., 0.19392361,
};
static const float bwh[] = {
    -0.14760374, ..., 0.08432186,
};
static const float uz[] = {
```

```
0.33544156, ..., -0.1061423,
};
static const float ur[] = {
0.3580518, ..., -0.09428676,
};
static const float uh[] = {
-0.21631242, ..., 0.07331745,
};
static const float buz[] = {
-0.17063044, ..., 0.1079701,
};
static const float bur[] = {
0.25578716, ..., 0.19392361,
};
static const float buh[] = {
-0.12483689, ..., 0.08706983,
};
static const float wz2[] = {
0.70549613, ..., -0.08304864,
};
static const float wr2[] = {
0.02348625, ..., 0.3856362,
};
static const float wh2[] = {
-0.5259535, ..., 0.52621037,
};
static const float bwz2[] = {
-0.17133844, ..., 0.10030975,
};
static const float bwr2[] = {
-0.14853013, ..., 0.07579752,
};
static const float bwh2[] = {
0.07097511, ..., 0.07575441,
};
static const float uz2[] = {
-0.30984527, ..., 0.03696784,
};
static const float ur2[] = {
-0.2557064, ..., 0.22604541,
};
static const float uh2[] = {
-0.21545862, ..., -0.16208637,
};
static const float buz2[] = {
-0.17133844, ..., 0.10030975,
};
static const float bur2[] = {
-0.14853013, ..., 0.07579752,
};
};
```

```
static const float buh2[] = {
    0.08364447, ..., 0.06608906,
};
static const float dense[] = {
    0.7647076, ..., 0.8833759,
};
static const float bias[] = {0.08102331};
```

Înainte de formatarea datelor de intrare, se stabilesc parametrii rețelei neuronale, utilizând parametrii de configurare din codul 5. Datele de intrare și de test trebuie definite conform codului 6.

Codul 5. Definirea arhitecturii rețelei neuronale

```
// this is the size of input sequence
#define INPUT_SIZE (5)
// this is the size for hidden layer
#define HIDDEN_SIZE (50)
#define NO_UNROLL INPUT_SIZE
```

Codul 6. Definirea intrărilor

```
static const float inputData[][INPUT_SIZE] = {
    {0.57, 0.546, 0.519, 0.519, 0.519, }, ...
    {0.495, 0.274, 0.091, -0.269, -0.512, },
};
static float testData[] = {
    0.518378626, ...
    -0.862251519,
};
```

Evaluarea propriu-zisă a implementării se face folosind apelul funcțiilor specifice PnP:

Codul 7. Rularea propriu-zisă a metodei

```
ModelInit();
ModelEvaluate();
```

7. EVALUAREA PERFORMANȚELOR

7.1. Criterii de evaluare

În vederea evaluării performanțelor am utilizat criteriile descrise la secțiunea 6. În plus, pentru validarea rețelei neuronale recurente am analizat repetabilitatea, validarea încrucișată și arhitectura rețelei.

7.2. Configurarea metodei

Configurarea metodei este sumarizată în tabelul de mai jos.

Tabel 3. Configurarea metodei de estimare bazată pe rețele neuronale de tip GRU

Parametru	Valoare
Nr. neuroni în nivelul 1	50
Nr. neuroni în nivelul 2	50
Nr. epoci antrenare	500
Nr. valori în fereastra de timp	5
Procent date antrenare + validare	80%
Procent date test	20%

În urma acestei configurări au rezultat următoarele caracteristici al rețelei:

Tabel 4. Caracteristici de antrenare a rețelei

Nr. total de parametri ai modelului	23001
Eroare medie absoluta la antrenare	0.0264

7.3. Rezultatele evaluării metodei pe setul de date NASA PCOE

În această secțiune voi prezenta rezultatele experimentale obținute în urma rulării metodei de estimare a stării de degradare a bateriilor pe întreg setul de date NASA PCOE. Specificațiile complete al acestui set de date sunt prezentate în Anexa 1.

Pentru evaluarea metodei propuse de estimare a stării de degradare a bateriilor folosind rețele neuronale recurente de tip GRU, a fost conceput un număr de 8 scenarii de test reprezentative pentru setul de date de baterii amintit mai sus. Alegerea scenariilor a fost făcută ținând cont de caracteristicile acestui set de date: curentul de descărcare, temperature de operare, tipul de chimie care prezintă fenomenul de regenerare. De asemenea au fost luate în considerare și scenariile folosite de alți autori (cele efectuate la curent constant la temperature ambientală) pentru comparație. Cele 8 scenarii de test sunt:

- 25-DEG-CC – setul de date ce conține date ale bateriilor ciclote în condiții de 25 de grade Celsius, curent de descărcare constant.
- ALL-DEG-CC – setul de date ce conține date ale bateriilor ciclote în toate condițiile de temperatură puse la dispoziție, curent de descărcare constant

- 25-DEG-CC-RW – setul de date ce conține date ale bateriilor ciclitate în condiții de 25 de grade Celsius, curent de descărcare constant și variabil.
- ALL-DEG-CC-RW – setul de date ce conține date ale bateriilor ciclitate în toate condițiile de temperatură puse la dispoziție, curent de descărcare constant și variabil.
- 25-DEG-CC-SF – setul de date ce conține date ale bateriilor ciclitate în condiții de 25 de grade Celsius, curent de descărcare constant.
- ALL-DEG-CC-SF – setul de date ce conține date ale bateriilor ciclitate în toate condițiile de temperatură puse la dispoziție, curent de descărcare constant
- 25-DEG-CC-RW-SF – setul de date ce conține date ale bateriilor ciclitate în condiții de 25 de grade Celsius, curent de descărcare constant și variabil.
- ALL-DEG-CC-RW-SF – setul de date ce conține date ale bateriilor ciclitate în toate condițiile de temperatură puse la dispoziție, curent de descărcare constant și variabil.

În figura de mai jos sunt prezentate intervalele de eroare rezultate în urma evaluării metodei propuse pentru cele 8 scenarii mai reprezentative




Fig. 34. Eroare relativă procentuală pentru cele 8 scenarii de evaluare semnificative

Datele au fost obținute prin rularea algoritmului în mediul de simulare Keras în versiunea 2.3 și tensorflow 2.1, folosind limbajul de programare Python, pe un PC cu procesor Intel core i7- 6700HQ, 2.6GHz, 8G RAM.

7.3.1. Evaluarea performanțelor pentru scenariul 25-DEG-CC

Pentru acest scenariu de test eroarea procentuală relativă de estimare se regăsește în intervalul [-5.7%, 1.35%]. Eroarea se încadrează în limitele uzuale întâlnite pentru metode bazate pe rețele neuronale care se află în intervalul [-5%, 5%]. Acest lucru se datorează faptului că la temperatura ambiantă de 25 grade, curbele de descărcare sunt destul de similare și nu prezintă neliniarități ce nu pot fi prezise cu o eroare inacceptabilă.




Fig. 35. Distribuția erorii de estimare în cadrul scenariului 25-DEG-CC

7.3.2. Evaluarea performanțelor pentru scenariul ALL-DEG-CC

În acest scenariu am adăugat curbe de descărcare la curent constant la toate temperaturile disponibile. În acest caz se observă că eroarea de estimare se situează în intervalul $[-5.32\%, 5.13\%]$. Se observă o creștere a erorii de estimare datorită neomogenității curbelor de descărcare pentru diferitele temperaturi luate în considerare.




Fig. 26. Distribuția erorii de estimare în cadrul scenariului ALL-DEG-CC

7.3.3. Evaluarea performanțelor pentru scenariul 25-DEG-CC-RW

Acest scenariu ia în considerare datele corespunzătoare descărcării cu curent constant la temperatura ambiantă de 25 de grade precum și datele corespunzătoare descărcării bateriilor cu curent variabil. Eroare de estimare se situează în intervalul $[-6.78\%, 6.55\%]$. Se observă o creștere a erorii față de setul de date obținut prin

descărcarea la curent constant datorită neliniarităților introduse de procesul de descărcare la curent variabil.




Fig. 37. Distribuția erorii de estimare în cadrul scenariului 25-DEG-CC-RW

7.3.4. Evaluarea performanțelor pentru scenariul ALL-DEG-CC-RW

Setul de date conține date aferente curbelor de descărcare la curent constant și curent variabil la toate temperaturile disponibile. În acest caz degradarea performanțelor de estimare se datorează atât introducerii neliniarităților produse de procesul de descărcare al bateriilor prin curent variabil cât și neomogenitățile introduse de utilizarea datelor pentru temperaturi diferite. Eroarea de estimare se află în intervalul $[-7.24\%, 6.31\%]$.




Fig. 38. Distribuția erorii de estimare în cadrul scenariului ALL-DEG-CC-RW

7.3.5. Evaluarea performanțelor pentru scenariul 25-DEG-CC-SF

O îmbunătățire considerabilă a erorilor de estimare se observă prin folosirea unui filtru de tip treaptă descris în secțiunea 5. Acest tip de filtru elimină neliniaritățile introduse de fenomenul de regenerare a capacității care se regăsește la unele tipuri de baterii, ca cel folosit în cazul de față. Prin intermediul introducerii filtrului se obține un set de curbe de al capacității strict descrescătoare. Eroare de estimare se regăsește în acest caz în intervalul $[-0.78\%, 1.22\%]$. De asemenea datorită modului de operare al fitrului se observă multiple puncte cu aceeași eroare de estimare.




Fig. 39. Distribuția erorii de estimare în cadrul scenariului 25-DEG-CC-SF

7.3.6. Evaluarea performanțelor pentru scenariul ALL-DEG-CC-SF

Introducerea filtrului de tip treaptă reduce cu eroare de estimare cu mai mult de 3% față de cazul în care datele nu sunt filtrate. Se obține un interval de eroare situat între limitele de -0.91% și 2.50% .




Fig. 40. Distribuția erorii de estimare în cadrul scenariului ALL-DEG-CC-SF

7.3.7. Evaluarea performanțelor pentru scenariul 25-DEG-CC-RW-SF

Introducerea filtrului de tip treaptă ajută într-o măsură mai mică în acest scenariu, neliniariitățile introduse de descărcarea cu curent variabil și neomogenitățile datorate diferitelor temperaturi păstrându-se și în datele filtrate. În acest caz eroare de estimare se află în intervalul -1.41% și 6.24%.




Fig. 41. Distribuția erorii de estimare în cadrul scenariului 25-DEG-CC-RW-SF

7.3.8. Evaluarea performanțelor pentru scenariul ALL-DEG-CC-RW-SF

Prin introducerea filtrului de tip treaptă în acest caz se obține un interval pentru eroarea de estimare care se apropie de intervalul de referință de -5%, 5% considerat uzual pentru acest tip de metodă de estimare.




Fig. 42. Distribuția erorii de estimare în cadrul scenariului ALL-DEG-CC-RW-SF

7.3.9. Analiza repetibilității pentru scenariul ALL-DEG-CC-RW-SF

Repetabilitatea este una din metricile importante folosite pentru a mă asigura că metoda implementată este una stabilă și nu suferă variații importante de la o rulare la alta. În acest context am executat un număr de 10 repetiții consecutive, reprezentând rezultatele în tabelul de mai jos. Pentru valoarea maximă superioară a erorii am obținut +6.79%, respectiv pentru valoarea maximă inferioară de -3.21%. Deviația maximă este de aproximativ 1% față de rezultatul de referință, fiind o valoare acceptabilă.




Fig. 43. Analiza repetibilității pentru scenariul ALL-DEG-CC-RW-SF

7.3.10. Analiza overfit/underfit pentru scenariul ALL-DEG-CC-RW-SF

Prin overfit se înțelege caracteristica modelului de a obține o bună generalizare strict pentru datele de învățare, iar pentru cele de test performanțe de estimare slabe. În sensul opus, discutăm de underfit, care este caracteristica modelului de a obține o slabă generalizare pentru datele de învățare precum și pentru cele de test.

În figura de mai jos se observă cum eroarea medie pătrată în cazul pasului de învățare urmărește trendul erorii medii pătrare obținute în cazul datelor de test. Acest lucru scoate în evidență o bună generalizare obținută prin rularea modelului.




Fig. 44. Analiza overfitt/underfitt pentru scenariul ALL-DEG-CC-RW-SF

7.3.11. Analiza structurii rețelei neuronale folosind scenariul ALL-DEG-CC-RW-SF

Pentru determinarea numărului optim de nivele ascunse respectiv numărul de celule pe nivel am derulat o serie de configurații ce conțin combinații ale acestor parametrii, urmărind intervalul de eroare relativă procentuală. Tabelul de mai jos sumarizează rezultatele obținute.

Din punct de vedere al structurii rețelei neuronale se poate concluziona că alegerea configurației cu un număr de 2 nivele ascunse și 50 de celule per nivel oferă rezultate bune, introducerea încă unui nivel ascuns neaducând o îmbunătățire semnificativă. De asemenea această configurație conferă posibilitatea implementării pe sisteme încorporate cu memorie RAM și FLASH redusă. Introducerea unui nivel ascuns adițional ar face ca stocarea parametrilor în memoria FLASH de 1MB să nu mai fie posibilă.

Tabel 5 Analiza structurii rețelei neuronale

Nr. nivele ascunse	Nr celule pe nivel	Interval eroare relativă procentuală
1	50	[-3,33, 6,94]
2	10	[-3.35, 6.96]
2	25	[-3.04, 6.82]
2	50	[-2.14, 6.68]
2	100	[-2.31, 6.7]
3	50	[-2.21, 6.49]

7.3.12. Analiza crossvalidare folosind scenariul ALL-DEG-CC-RW-SF

Crossvalidarea sau validarea încrucișată este de asemenea o metrică pentru analiza calității procesului de învățare. De asemenea această metrică poate să confere o imagine de ansamblu asupra gradului de omogenitate a setului de date. Datorită tipului de estimare, și anume a seriilor de timp, am folosit ca și metrică

pătratul coeficientului de corelație r , întâlnit și sub denumirea de coeficient de determinare.

Pentru analiza validării încrucișate am folosit 10 subdivizări a setului de date. Tabelul următor sintetizează valorile coeficientului de determinare pentru cele 10 rulări:

Tabel 6. Valoarea parametrului de corelație pentru pașii de crossvalidare

Pas crossvalidare	Valoare r^2
1	0.9949
2	0.9981
3	0.9977
4	0.9974
5	0.9975
6	0.9983
7	0.9976
8	0.9975
9	0.9963
10	0.9982

Pentru exemplificare am afișat graficul corespunzător coeficientului de determinare pentru pasul 1 în cadrul validării încrucișate.




Fig. 45. Parametru de corelație pentru pasul 1 de crossvalidare

7.3.13. Evaluarea implementării metodei pe sisteme încorporate

Pentru evaluarea implementării metodei pe sisteme încorporate am ales setul de platforme fizice (vezi Fig. 46) ale căror specificații sunt sintetizate în tabelul următor:




Fig. 46. Platforme fizice folosite

Tabel 7. Lista platformelor HW și configurarea SW pentru evaluarea implementării metodei pe sisteme încorporate

Platforma	EFM32GG	Nordic nRF52840	Raspberry pi 4	NVidia jetson nano
Hardware	Silicon Labs EFM32GG990F1024 48 MHz ARM Cortex M3 32 bit 128 KB RAM 1MB flash	Nordic semiconductor nRF52840 64MHz ARM Cortex M4 32 bit cu unitate FPU 256 KB RAM 1 MB flash	Broadcom BCM2711 Quad core 1.5 GHz 64 bit ARM Cortex A-72 4GB LPDDR4-3200 SDRAM	Nvidia GPU 128 – core Maxwell Quas core ARM A57 1.43 GHz 4GB LPDDR4 SDRAM
Software	Mbed OS	Mbed OS	Raspbian	Ubuntu Linux
Compiler / translator	gcc 7.2.1 arm-none- eabi	gcc 7.2.1 arm-none- eabi	gcc 8.3.0 arm-linux gnullabi / python 3.6 + tensorflow 2.1	gcc 8.3.0 arm-linux gnullabi / python 3.6 + tensorflow gpu 2.2

Am folosit două implementări ale metodei: cea bazată pe platforma PnP (C/C++) și cea bazată pe python (Keras) și tensorflow. Ca și criterii de evaluare am ales timpul de execuție, memoria ocupată, consum și eroarea de estimare. Rezultatele complete se pot regăsi în tabelul de mai jos:

Tabel 8. Evaluarea implementării metodelor pe sisteme încorporate

Platformă sistem / Implementare	PnP			
	Eroare estimare	Timp estimare [s]	Memorie utilizată [bytes]	Consum energie
EFM32GG	PC	24.537 s	RAM: 125400 FLASH: 291916	0.0825A 5.06V
nRF52840	PC	3.925 s	RAM: 132664 FLASH: 286456	0.107A 5.04V
Raspberry Pi4	PC	0.1042	.text 13392 .data 2464 .rodata 251746 .bss 126145	0.477A 5.02V
Nvidia jetson nano	PC	0.1397 s	.text 14220 .data 2712 .rodata 251939 .bss 127329	0.827A 5.03V
Platformă sistem / Implementare	Keras (tensorflow)			
	Eroare estimare	Timp estimare [s]	Memorie utilizată [bytes]	Consum energie
EFM32GG	N/A	N/A	N/A	N/A
nRF52840	N/A	N/A	N/A	N/A
Raspberry Pi4	PC	0.1042	.text 13392 .data 2464 .rodata 251746 .bss 126145	0.477A 5.02V
Nvidia jetson nano	PC	3 (prima estimare) 0.049 (restul estimărilor)	Max. 29853999	1.02 A 5.04 V

7.4. Discutarea rezultatelor și studiul comparativ cu alte metode

Voi începe discutarea rezultatelor prin prezentarea concluziilor recente referitoare la performanțele de estimare ale metodelor existente în termeni de eroare maximă și minimă 0. Acestea se pot regăsi în figura 45

Metodele bazate pe filtru Kalman și derivatele acestora se caracterizează printr-o eroare de estimare de maxim 5% și minim 2.5%. Aceste rezultate au fost obținute în marea lor majoritate pe medii de simulare pe PC, neexistând o corelație clară cu resursele utilizate și posibilitatea implementării în sisteme reale de management al bateriilor.

Un interval mai larg de erori îl prezintă metodele bazate pe observatori (modele matematice). Erorile de estimare se încadrează între maxim 10% și minim 2.5%. Într-un mod asemănător se comportă și metodele bazate pe regresie în sensul celor mai mici pătrate (polinomială, exponențială), cele din urmă prezentând avantajul resurselor computaționale reduse și totodată facilitatea implementării în sisteme încorporate.

Conform 0 metodele bazate pe logica fuzzy prezintă o eroare de estimare situată în intervalul [2.5%, 5%]. Deși această metodă nu impune un efort computațional substanțial, eroarea de estimare depinde mult de modelul ales și de setul de date, cel mai important dezavantaj fiind cel al necesității unui set de date mult mai mare ca cel necesar metodelor bazate pe rețele neuronale




Fig. 47. Acuratețea estimării pentru diferite metode de estimare a stării de degradare a bateriilor 0

Metodele bazate pe ciclul de viață (de degradare) al bateriei prezintă o acuratețe mai mare, eroarea de estimare se situează în intervalul [1.5%, 5%]. În general aceste metode se bazează pe analiza datelor de laborator obținute offline în urma ciclării intensive a bateriilor în diferite condiții.

Metodele bazate pe rețele neuronale prezintă cea mai mare acuratețe conform 0. 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 ambiantă de 25 de grade Celsius, încărcarea și descărcarea făcându-se cu un curent constant. Acest lucru 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 curenți 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 [3] cum ar fi LSTM, metoda bazată pe celule GRU are avantajul că prezintă o structură mai simplă a celei 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 următor sumarizează comparația modelului GRU cu LSTM

Tabel 9. Comparație între rețele neuronale LSTM și GRU [3]

Criteria	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 [3] 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.




Fig. 48. Studiu comparativ a principalelor metode de estimare cu implementare pe sisteme încorporate [3]

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 așa de semnificativă. Acest lucru se poate observa la bateria B0032. Chiar și așa, eroarea de estimare se află într-un interval acceptabil.

8. CONCLUZII ȘI PERSPECTIVE

8.1. Concluzii

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.

Lucrarea abordează probleme curente din domeniul bateriilor și a sistemelor încorporate cu resurse limitate de procesare.

Principalele obiective ale tezei sunt descrise în secțiunea 1.3:

- 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 acuratețe de estimare cât mai ridicată în ceea ce privește SoH, respectiv
 - 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:
 - criterii de precizie și acuratețe,
 - criterii de evaluare a complexității algoritmilor,
 - criterii de evaluare a resurselor de microprocesor utilizare precum și a consumului propriu de energie al algoritmului.

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 capacității. 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 încorporate de la cele mai simple ajungând la cele mai complexe în funcție de platforma 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 metrici prin care să se poată 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.

8.2. Rezumat al contribuțiilor

Lista completă a contribuțiilor din această lucrare este prezentată mai jos:

- Capitolul 3: am realizat o analiză complexă a principalelor metode de evaluare a stării de degradare a bateriilor scoțând în evidență avantajele și dezavantajele fiecăreia.
- Capitolul 4: Am prezentat descrierea și implementarea unei metode simple și eficiente de estimare a stării de degradare a bateriilor bazate pe regresii polinomiale de ordin 2.
- Capitolul 5: Am detaliat metoda de estimare a stării de degradare a bateriilor bazate pe rețele neuronale recurente de tip GRU. În plus am descris optimizarea necesară pentru baterii care prezintă efectul de regenerare a capacității.
- Capitolul 6: Am descris și implementat un sistem cadru pentru evaluarea performanțelor metodelor de estimare a bateriilor în vederea posibilității comparării acestora.
- Capitolul 7: Am utilizat sistemul cadru descris la capitolul 6 pentru analiza performanțelor metodei de evaluare a stării de degradare a bateriilor în diverse implementări pe sisteme încorporate. În plus am luat în considerare prezentarea unui studiu comparativ cu alte metode existente.

8.3. Perspective de cercetare și dezvoltare

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 ficși 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.

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

- Lărgirea plajei de sisteme încorporate 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 BIBLIOGRAFICE

- [1] L. Ungurean, G. Cârstoiu, M. V. Micea, and V. Groza, 'Battery state of health estimation: a structured review of models, methods and commercial devices', *Int J Energ Res Int J Energ Res*, vol. 41, no. 2, pp. 151-181, Feb. 2017
- [2] V. Pop, H. J. Bergveld, D. Danilov, P. P. L. Regtien, and P. H. L. Notten, *Battery Management Systems. Accurate State-of-Charge Indication for Battery-Powered Applications*. Springer Netherlands, 2008.
- [3] 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.
- [4] Z. Guo, X. Qiu, G. Hou, B.Y. Liaw, C. Zhang, "State of Health Estimation for Lithium Ion Batteries Based on Charging Curves", *J. Power Sources*, 249, 2014, (457-462).
- [5] 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).
- [6] W. Waag, C. Fleischer, D.U. Sauer, "Adaptive On-Line Prediction of the Available Power of Lithium-Ion Batteries", *J. Power Sources*, 242, 2013, (548-559).
- [7] A.H. Ranjbar, A. Banaei, A. Khoobroo, B. Fahimi, "Online Estimation of State of Charge in Li-Ion Batteries Using Impulse Response Concept", *IEEE Trans Smart Grid*, 3 (1), 2012, (360-367).
- [8] K.M. Tsang, L. Sun, W.L. Chan, "Identification and Modelling of Lithium Ion Battery", *Energ. Convers. Managem.*, 51, 2010, (2857-2862).
- [9] Y. Xing, W. He, M. Pecht, K.L. Tsui, "State of Charge Estimation of Lithium-Ion Batteries Using the Open-Circuit Voltage at Various Ambient Temperatures", *Applied Energ.*, 113, 2014, (106-115).
- [10] J. Remmlinger, M. Buchholz, et al., "State-of-Health Monitoring of Lithium-Ion Batteries in Electric Vehicles by On-Board Internal Resistance Estimation", *J. Power Sources*, 196, 2011, (5357-5363).
- [11] Z. Chen, C.C. Mi, Y. Fu, J. Xu, X. Gong, "Online Battery State of Health Estimation Based on Genetic Algorithm for Electric and Hybrid Vehicle Applications", *J. Power Sources*, 240, 2013, (184-192).
- [12] S.E. Li, B. Wang, H. Peng, X. Hu, "An Electrochemistry-Based Impedance Model for Lithium-Ion Batteries", *J. Power Sources*, 258, 2014, (9-18).
- [13] G.K. Prasad, C.D. Rahn, "Model Based Identification of Aging Parameters in Lithium Ion Batteries", *J. Power Sources*, 232, 2013, (79-85).
- [14] M. Ecker, J.B. Gerschler, J. Vogel, S. Kabitz, F. Hust, P. Dechent, D.U. Sauer, "Development of a Lifetime Prediction Model for Lithium-Ion Batteries Based on Extended Accelerated Aging Test Data", *J. Power Sources*, 215, 2012, (248-257).

- [15] L.C. Stevanatto, V.J. Brusamarello, S. Tairov, "Parameter Identification and Analysis of Uncertainties in Measurements of Lead-Acid Batteries", *IEEE Trans. Instrum. Meas.*, 63 (4), 2014, (761-768).
- [16] 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).
- [17] S.J. Moura, N.A. Chaturvedi, M. Krstic, "PDE Estimation Techniques for Advanced Battery Management Systems - Part II: SOH Identification", in *Proc. IEEE ACC*, 2012, (566-571).
- [18] S.J. Moura, N.A. Chaturvedi, M. Krstic, "PDE Estimation Techniques for Advanced Battery Management Systems - I: SOC Estimation", in *Proc. IEEE ACC*, 2012, (559-565).
- [19] S. Santhanagopalan, R.E. White, "State of Charge Estimation Using an Unscented Filter for High Power Lithium Ion Cells", *Int. J. Energ. Research*, 34, 2010, (152-163).
- [20] 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).
- [21] C. Weng, Y. Cui, J. Sun, H. Peng, "On-Board State of Health Monitoring of Lithium-Ion Batteries Using Incremental Capacity Analysis With Support Vector Regression", *J. Power Sources*, 235, 2013, (36-44).
- [22] 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).
- [23] Y. Xing, E.W.M. Ma, K.L. Tsui, M. Pecht, "An Ensemble Model for Predicting the Remaining Useful Performance of Lithium-Ion Batteries", *Microelectron. Reliab.*, 53 (6), 2013, (811-820).
- [24] X. Hu, S.E. Li, Z. Jia, B. Egardt, "Enhanced Sample Entropy-Based Health Management of Li-Ion Battery for Electrified Vehicles", *Energy*, 64, 2014, (953-960).
- [25] M. Mastali, J. Vazquez-Arenas, R. Fraser, M. Fowler, S. Afshar, M. Stevens, "Battery State of the Charge Estimation Using Kalman Filtering", *J. Power Sources*, 239, 2013, (294-307).
- [26] N. Omar, M.A. Monem, et al., "Lithium Iron Phosphate Based Battery - Assessment of the Aging Parameters and Development of Cycle Life Model", *Applied Energ.*, 113, 2014, (1575-1585).
- [27] Y. Xing, K.L. Tsui, Q. Miao, M. Pecht, "Prognostics and Health Monitoring for Lithium-Ion Battery", in *Proc. IEEE ISI*, 2011, (242-247).
- [28] J.A.M. Penna, C.L. Nascimento Jr., L.R. Rodrigues, "Health Monitoring and Remaining Useful Life Estimation of Lithium-Ion Aeronautical Batteries", in *Proc. IEEE AERO*, 2012, (1-12).
- [29] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, 'Statistical and Machine Learning forecasting methods: Concerns and ways forward', *PLOS ONE*, vol. 13, no. 3, p. e0194889, Mar. 2018, doi: 10.1371/journal.pone.0194889.

- [30] M. T. Hagan, H. B. Demuth, M. H. Beale, and O. De Jesus, *Neural network design*, 2nd edition, 2016.
- [31] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. Cambridge, Massachusetts: The MIT Press, 2016.
- [32] F. A. Gers, J. Schmidhuber, and F. Cummins, 'Learning to forget: continual prediction with LSTM', in 1999 Ninth International Conference on Artificial Neural Networks ICANN 99. (Conf. Publ. No. 470), Sep. 1999, vol. 2, pp. 850–855 vol.2, doi: 10.1049/cp:19991218.
- [33] S. Hochreiter and J. Schmidhuber, 'Long Short-Term Memory', *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [34] K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber, 'LSTM: A Search Space Odyssey', *IEEE Transactions on Neural Networks and Learning Systems*, vol. 28, no. 10, pp. 2222–2232, Oct. 2017, doi: 10.1109/TNNLS.2016.2582924.
- [35] Christopher Olah, Understanding LSTM Networks, <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>, 2015.
- [36] R. Dey and F. M. Salem, 'Gate-variants of Gated Recurrent Unit (GRU) neural networks', in 2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS), Aug. 2017, pp. 1597–1600, doi: 10.1109/MWSCAS.2017.8053243.
- [37] 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).
- [38] L. Lu, X. Han, J. Li, J. Hua, M. Ouyang, "A Review on the Key Issues for Lithium-Ion Battery Management in Electric Vehicles", *J. Power Sources*, 226, 2013, (272–288).
- [39] B. Price, J. Richardson, E. Dietz, "State-of-Charge and State-of-Health Monitoring: Implications for Industry, Academia, and the Consumer", in *Proc. IEEE EIT*, 2012, (1–6).
- [40] J. Zhang, J. Lee, "A Review on Prognostics and Health Monitoring of Li-Ion Battery", *J. Power Sources*, 196, 2011, (6007–6014).
- [41] 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).
- [42] A. Barre, B. Deguilhem, et al., "A Review on Lithium-Ion Battery Ageing Mechanisms and Estimations for Automotive Applications", *J. Power Sources*, 241, 2013, (680–689).
- [43] K.B. Hatzell, A. Sharma, H.K. Fathy, "A Survey of Long-Term Health Modeling, Estimation, and Control of Lithium-Ion Batteries: Challenges and Opportunities", in *Proc. AACC*, 2012, (584–591).
- [44] S.M. Rezvanizani, et al., "Review and Recent Advances in Battery Health Monitoring and Prognostics Technologies for Electric Vehicle (EV) Safety and Mobility", *J. Power Sources*, 256, 2014, (110–124).

- [45] L. Liao, F. Kottig, "Review of Hybrid Prognostics Approaches for Remaining Useful Life Prediction of Engineered Systems, and an Application to Battery Life Prediction", *IEEE Trans. Reliab.*, 63 (1), 2014.
- [46] A. Seaman, et al., "A Survey of Mathematics-Based Equivalent-Circuit and Electrochemical Battery Models for Hybrid and Electric Vehicle Simulation", *J. Power Sources*, 256, 2014, (410–423).
- [47] 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).
- [48] B.P. Divakar, K.W.E. Cheng, et al., "Battery Management System and Control Strategy for Hybrid and Electric Vehicle", in Proc. PESA, 2009, (1-6).
- [49] A. Saxena, " Subject MI63: Kalman Filter Tank Filling", Cornell Univ., 2008, Online:
<http://www.cs.cornell.edu/courses/cs4758/2012sp/materials/mi63slides.pdf>.
- [50] 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).
- [51] D. Andre, A.], 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 Batteries in Hybrid Electric Vehicles", *Eng. Applic. Artif. Intellig.*, 26, 2013, (951-961).
- [52] M. Daboussy, D. Chrenko, et al., "Characterisation of a Commercial Automotive Lithium Ion Battery Using Extended Kalman Filter", in Proc. IEEE ITEC, 2013, (1-6).
- [53] J. Kim, S. Lee, B.H. Cho, "Complementary Cooperation Algorithm Based on DEKF Combined With Pattern Recognition for SOC/Capacity Estimation and SOH Prediction", *IEEE Trans. Power Electron.*, 27 (1), 2012, (436-451).
- [54] T. Dragicevic, S. Sucic, J.M. Guerrero, "Battery State-of-Charge and Parameter Estimation Algorithm Based on Kalman Filter", in Proc. IEEE EuroCon, 2013, (1519–1524).
- [55] B. Pivlelait, C. Rentel, et al., "An Advanced Battery Management System for Lithium Ion Batteries", in Proc. GVSETS, 2011, (1-7).
- [56] D. Andre, C. Appel, T. Soczka-Guth, D.U. Sauer, "Advanced Mathematical Methods of SOC and SOH Estimation for Lithium-Ion Batteries", *J. Power Sources*, 224, 2013, (20–27).
- [57] E.A. Wan, R. Van Der Merwe, "The Unscented Kalman Filter for Nonlinear Estimation", in Proc. IEEE AS-SPCC, 2000, (153–158).
- [58] B. Bole, C.S. Kulkarni, M. Daigle, "Adaptation of an Electrochemistry-Based Li-Ion Battery Model to Account for Deterioration Observed Under Randomized Use", in Proc. PHM14, 2014, (1-9).
- [59] C. Barlak, Y. Ozkazanc, "A Classification Based Methodology for Estimation of State-of-Health of Rechargeable Batteries", in Proc. IEEE ELECO, 2009, (II.101–II.105).

- [60] J. Kim, B.H. Cho, "State-of-Charge Estimation and State-of-Health Prediction of a Li-Ion Degraded Battery Based on an EKF Combined With a Per-Unit System", *IEEE Trans. Vehicular Tech.*, 60 (9), 2011.
- [61] J. Remmlinger, M. Buchholz, T. Soczka-Guth, K. Dietmayer, "On-Board State-of-Health Monitoring of Lithium-Ion Batteries Using Linear Parameter-Varying Models", *J. Power Sources*, 239, 2013, (689-695).
- [62] J.D. Kozłowski, "Electrochemical Cell Prognostics Using Online Impedance Measurements and Model-Based Data Fusion Techniques", in *Proc. IEEE AERO*, 2003, (3257-3270).
- [63] 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).
- [64] K.M. Tsang, W.L. Chan, "State of Health Detection for Lithium Ion Batteries in Photovoltaic System", *Energ. Convers. Manag.*, 65, 2013, (7-12).
- [65] M. Landi, G. Gross, "Measurement Techniques for Online Battery State of Health Estimation in Vehicle-to-Grid Applications", *IEEE Trans. Instrum. Meas.*, 63 (5), 2014, (1224-1234).
- [66] A.J. Smola, B. Schölkopf, "A Tutorial on Support Vector Regression", *Statistics Comput.*, 14 (3), 2004, (199-222).
- [67] A. Widodo, M.C. Shim, W. Caesarendra, B.S. Yang, "Intelligent Prognostics for Battery Health Monitoring Based on Sample Entropy", *Expert Syst. Applic.*, 38, 2011, (11763-11769).
- [68] 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).
- [69] B. Pattipati, C. Sankavaram, K.R. Pattipati, "System Identification and Estimation Framework for Pivotal Automotive Battery Management System Characteristics", *IEEE Trans. Syst. Man Cybernetics C*, 41 (6), 2011, (869-884).
- [70] J. Zhou, D. Liu, Y. Peng, X. Peng, "Dynamic Battery Remaining Useful Life Estimation: An On-Line Data-Driven Approach", in *Proc. IEEE I2MTC*, 2012, (2196-2199).
- [71] A. Nuhic, T. Terzimehic, et al., "Health Diagnosis and Remaining Useful Life Prognostics of Lithium-Ion Batteries Using Data-Driven Methods", *J. Power Sources*, 239, 2013, (680-688).
- [72] C. Weng, Y. Cui, J. Sun, H. Peng, "On-Board State of Health Monitoring of Lithium-Ion Batteries Using Incremental Capacity Analysis With Support Vector Regression", *J. Power Sources*, 235, 2013, (36-44).
- [73] B. Saha, K. Goebel, S. Poll, J. Christophersen, "An Integrated Approach to Battery Health Monitoring Using Bayesian Regression and State Estimation", in *Proc. IEEE Autotestcon*, 2007, (646-653).
- [74] 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).
- [75] K. Goebel, B. Saha, A. Saxena, J.R. Celaya, J.P. Christophersen, "Prognostics in Battery Health Management", *IEEE Instrum. Meas. Mag.*, 11 (4), 2008, (33-40).

- [76] B. Saha, K. Goebel, S. Poll, J. Christophersen, "Prognostics Methods for Battery Health Monitoring Using a Bayesian Framework", *IEEE Trans. Instrum. Meas.*, 58 (2), 2009, (291-296).
- [77] 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).
- [78] Y. Xing, E.W.M. Ma, K.L. Tsui, M. Pecht, "An Ensemble Model for Predicting the Remaining Useful Performance of Lithium-Ion Batteries", *Microelectron. Reliab.*, 53, 2013, (811-820).
- [79] W. Xian, B. Long, M. Li, H. Wang, "Prognostics of Lithium-Ion Batteries Based on the Verhulst Model, Particle Swarm Optimization and Particle Filter", *IEEE Trans. Instrum. Meas.*, 63 (1), 2014, (2-17).
- [80] W. He, N. Williard, M. Osterman, M. Pecht, "Prognostics of Lithium-Ion Batteries Based on Dempster-Shafer Theory and the Bayesian Monte Carlo Method", *J. Power Sources*, 196, 2011, (10314-10321).
- [81] W. He, N. Williard, M. Osterman, M. Pecht, "Remaining Useful Performance Analysis of Batteries", in *Proc. IEEE PHM*, 2011, (1-6).
- [82] 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).
- [83] D.Z. Li, W. Wang, F. Ismail, "A Mutated Particle Filter Technique for System State Estimation and Battery Life Prediction", *IEEE Trans. Instrum. Meas.*, 63 (8), 2014, (2034-2043).
- [84] G. Li, B. Li, Z. Liu, X. Chen, "Implementation and Optimization of Particle Filter Tracking Algorithm on Multi-DSPs System", in *Proc. IEEE CIS*, 2008, (152-157).
- [85] Q. Miao, L. Xie, H. Cui, W. Liang, M. Pecht, "Remaining Useful Life Prediction of Lithium-Ion Battery With Unscented Particle Filter Technique", *Microelectron. Reliab.*, 53, 2013, (805-810).
- [86] M.E. Orchard, L. Tang, G. Vachtsevanos, "A Combined Anomaly Detection and Failure Prognosis Approach for Estimation of Remaining Useful Life in Energy Storage Devices", in *Proc. PHM11*, 2011, (1-7).
- [87] C. Chen, M. Pecht, "Prognostics of Lithium-Ion Batteries Using Model-Based and Data-Driven Methods", in *Proc. IEEE PHM*, 2012, (1-6).
- [88] 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).
- [89] X. Hu, S.E. Li, Z. Jia, B. Egardt, "Enhanced Sample Entropy-Based Health Management of Li-Ion Battery for Electrified Vehicles", *Energy*, 64, 2014, (953-960).
- [90] Y.H. Sun, H.L. Jou, J.C. Wu, K.D. Wu, "Auxiliary Health Diagnosis Method for Lead-Acid Battery", *Applied Energ.*, 87, 2010, (3691-3698).
- [91] M. Gholizadeh, F.R. Salmasi, "Estimation of State of Charge, Unknown Nonlinearities, and State of Health of a Lithium-Ion Battery Based on a Comprehensive Unobservable Model", *IEEE Trans. Ind. Electron.*, 61 (3), 2014, (1335-1344).

- [92] X. Feng, J. Li, M. Ouyang, et al., "Using Probability Density Function to Evaluate the State of Health of Lithium-Ion Batteries", *J. Power Sources*, 232, 2013, (209-218).
- [93] J. Yu, "Health Degradation Detection and Monitoring of Lithium-Ion Battery Based on Adaptive Learning Method", *IEEE Trans. Instrum. Meas.*, 63 (7), 2014, (1709-1721).
- [94] D. Liu, J. Pang, J. Zhou, Y. Peng, M. Pecht, "Prognostics for State of Health Estimation of Lithium-Ion Batteries Based on Combination Gaussian Process Functional Regression", *Microelectron. Reliab.*, 53, 2013, (832-839).
- [95] S. Tang, C. Yu, X. Wang, X. Guo, X. Si, "Remaining Useful Life Prediction of Lithium-Ion Batteries Based on the Wiener Process with Measurement Error", *Energies*, 7, 2014, (520-547).
- [96] 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, 2013, (821-831).
- [97] M. Shahriari, M. Farrokhi, "Online State-of-Health Estimation of VRLA Batteries Using State of Charge", *IEEE Trans. Ind. Electron.*, 60 (1), 2013, (191-202).
- [98] 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).
- [99] 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).
- [100] 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).
- [101] A. Eddahech, O. Briat, E. Woirgard, J.M. Vinassa, "Remaining Useful Life Prediction of Lithium Batteries in Calendar Ageing for Automotive Applications", *Microelectr. Reliab.*, 52, 2012, (2438-2442).
- [102] M. V. Micea, G. N. Carstoiu, L. Ungurean, D. Chiciudean, V. I. Cretu, V. Groza, "PARSECS: A Predictable Data Communication System for Smart Sensors and Hard Real-Time Applications", *IEEE Trans. Instrum. Meas.*, 14 pg., 2010
- [103] Texas Instruments, "TMP101: Digital Temperature Sensor with I2CTM Interface", Datasheet Rev. G, Texas Instruments, 2007.
- [104] Mihai V. Micea, V. Cretu, V. Groza, "Maximum Predictability in Signal Interactions with HARETICK Kernel", *IEEE Trans. Instrum. Meas.*, vol. 55, no. 4, pp. (1317-1330), Aug. 2006

PUBLICAȚII

Publicații cotate ISI:

G. Cârstoiu, M. V. Micea, L. Ungurean, and M. Marcu, 'Novel battery wear leveling method for large-scale reconfigurable battery packs', *International Journal of Energy Research*, vol. 45, no. 2, pp. 1932–1947, Feb. 2021, doi: [10.1002/er.5879](https://doi.org/10.1002/er.5879). – nr. citări 1

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](https://doi.org/10.1002/er.5413). – nr. citări 16

L. Ungurean, G. Carstoiu, M. V. Micea, and V. Groza, 'Battery state of health estimation: a structured review of models, methods and commercial devices', *Int J Energ Res Int J Energ Res*, vol. 41, no. 2, pp. 151–181, Feb. 2017. – nr. citări 110

M. V. Micea, L. Ungurean, G. N. Carstoiu, and V. Groza, 'Online State-of-Health Assessment for Battery Management Systems', *Ieee T Instrum Meas Ieee T Instrum Meas*, vol. 60, no. 6, pp. 1997–2006, Jun. 2011. – nr. citări 95

M. V. Micea, G. N. Carstoiu, L. Ungurean, D. Chiciudean, V. I. Cretu, and V. Groza, 'PARSECS: A Predictable Data Communication System for Smart Sensors and Hard Real-Time Applications', *Ieee T Instrum Meas Ieee T Instrum Meas*, vol. 59, no. 11, pp. 2968–2981, Nov. 2010.

M. V. Micea, G. N. Carstoiu, L. Ungurean, D. Chiciudean, V. Cretu, and V. Groza, 'Predictable data communication interface for hard real-time systems', Oct. 2008, pp. 98–101. doi: [10.1109/ROSE.2008.4669188](https://doi.org/10.1109/ROSE.2008.4669188).

ANEXA 1. DESCRIEREA SETULUI DE DATE NASA PROGNOSTICS CENTER OF EXCELLENCE

Cod baterie	Condiții pentru ridicarea curbelor de încărcare/descărcare
B005 B006 B007 B0018	Temperatura de operare: 25 grade C Curent încărcare: 1.5A Tensiune finală de încărcare: 4.2V Curent de descărcare: 2A constant Tensiune finală de descărcare: 2V
B0025 B0026 B0027 B0028	Temperatura de operare: 25 grade C Curent încărcare: 1.5A Tensiune finală de încărcare: 4.2V Curent de descărcare: puls de 0.05Hz cu amplitudine de 4A, factor de umplere 50% Tensiune finală de descărcare: 2V
B0029 B0028 B0030 B0031	Temperatura de operare: 25 grade C Curent încărcare: 1.5A Tensiune finală de încărcare: 4.2V Curent de descărcare: 4A Tensiune finală de descărcare: 2V
B0033 B0034 B0036	Temperatura de operare: 25 grade C Curent încărcare: 1.5A Tensiune finală de încărcare: 4.2V Curent de descărcare: 2A constant Tensiune finală de descărcare: 2V
B0038 B0039 B0040	Temperatura de operare: 25 grade C și 44 grade C Curent încărcare: 1.5A Tensiune finală de încărcare: 4.2V Curent de descărcare: 1A, 2A, 4A, constant Condiția de oprire: până când valoarea capacității a scăzut cu 20% față de valoarea capacității inițiale
B0041 B0042 B0043 B0044	Temperatura de operare: 4 grade C Curent încărcare: 1.5A Tensiune finală de încărcare: 4.2V Curent descărcare: 1A, 4A constant
B0049 B0050 B0051 B0052	Temperatura de operare: 4 grade C Curent încărcare: 1.5A Tensiune finală de încărcare: 4.2V Curent descărcare: 2A constant
B0053 B0054 B0055 B0056	Temperatura de operare: 4 grade C Curent încărcare: 1.5A Tensiune finală de încărcare: 4.2V Curent de descărcare: puls de 0.01Hz-5kHz cu amplitudine de 2A, factor de umplere

	50% Condiția de oprire: până când valoarea capacității a scăzut cu 30% față de valoarea capacității inițiale
RW1 RW2 RW7 RW8	Temperatura de operare: 25 grade C Durată încărcare: 0.5 – 3 ore Profil descărcare: curent aleator 0.5A - 4A Condiția de oprire: tensiunea la borne 3.2V
RW3 RW4 RW5 RW6	Temperatura de operare: 25 grade C Încărcare: valoarea tensiunii la borne 4.2V Profil descărcare: curent aleator 0.5A - 4A Condiția de oprire: tensiunea la borne 3.2V
RW25 RW26 RW27 RW28	Temperatura de operare: 40 grade C Încărcare: valoarea tensiunii la borne 4.2V Profil descărcare: curent aleator 0.5A - 5A Condiția de oprire: tensiunea la borne 3.2V Se folosește următoarea funcție de probabilitate pentru a selecta curentul de descărcare la fiecare minut: 0.5A 2.0% 1.0A 2.4% 1.5A 3.6% 2.0A 6.0% 2.5A 9.2% 3.0A 11.8% 3.5A 17.2% 4.0A 23.4% 4.5A 19.4% 5.0A 5.0%
RW17 RW18 RW19 RW20	Temperatura de operare: 25 grade C Încărcare: valoarea tensiunii la borne 4.2V Profil descărcare: curent aleator 0.5A - 5A Condiția de oprire: tensiunea la borne 3.2V Se folosește următoarea funcție de probabilitate pentru a selecta curentul de descărcare la fiecare minut: 0.5A 2.0% 1.0A 2.4% 1.5A 3.6% 2.0A 6.0% 2.5A 9.2% 3.0A 11.8% 3.5A 17.2% 4.0A 23.4% 4.5A 19.4% 5.0A 5.0%
RW21 RW22 RW23 RW24	Temperatura de operare: 40 grade C Încărcare: valoarea tensiunii la borne 4.2V Profil descărcare: curent aleator 0.5A - 5A Condiția de oprire: tensiunea la borne 3.2V

	<p>Se folosește următoarea funcție de probabilitate pentru a selecta curentul de descărcare la fiecare minut:</p> <p>0.5A 7.2% 1.0A 14.8% 1.5A 19.3% 2.0A 21.6% 2.5A 14.6% 3.0A 10.0% 3.5A 6.5% 4.0A 4.0% 4.5A 1.5% 5.0A 0.5%</p>
RW13 RW14 RW15 RW16	<p>Temperatura de operare: 25 grade C Încărcare: valoarea tensiunii la borne 4.2V Profil descărcare: curent aleator 0.5A - 5A Condiția de oprire: tensiunea la borne 3.2V Se folosește următoarea funcție de probabilitate pentru a selecta curentul de descărcare la fiecare minut:</p> <p>0.5A 7.2% 1.0A 14.8% 1.5A 19.3% 2.0A 21.6% 2.5A 14.6% 3.0A 10.0% 3.5A 6.5% 4.0A 4.0% 4.5A 1.5% 5.0A 0.5%</p>

