



Comparison of Li-Ion Battery State of Charge Prediction by Artificial Neural Network and Adaptive Neuro Fuzzy Inference System

ARTICLE INFO

Article Type

Original Research

Authors

Nouri Khajavi M.*¹ PhD,
Bayat Gh.R.¹ MSc

How to cite this article

Nouri Khajavi M, Bayat Gh.R. Comparison of Li-Ion Battery State of Charge Prediction by Artificial Neural Network and Adaptive Neuro Fuzzy Inference System. Modares Mechanical Engineering. 2019; 19(1):43-52.

ABSTRACT

An accurate estimation of the state of charge is necessary not only for optimal management of the energy in the electric vehicles (EV) and smart grids, but also to protect the battery from going to the deep discharge or overcharge conditions that degrades battery life and may create potentially dangerous situations like explosion. Despite the importance of this parameter, the state of charge cannot be measured directly from the battery terminals. In this research, an electric equivalent circuit model is simulated in the Simulink environment with two RC networks. This model has the advantage of providing a quick test for the extraction of parameters and dynamic characteristics of the battery model, but is not suitable for on-line applications in an EV. This is why algorithms need to be developed to estimate the SOC of the battery pack and the individual cells based on the measured data of each one. In this paper, for the validation of the neural network, a discharge rate of 0.6A and in the adaptive neuro fuzzy inference system (ANFIS) network, the discharge rate of 0.8, 0.1, and 0.45 was used. The comparison of ANFIS method with the neural method in this study showed that the ANFIS method is more accurate in estimating the state of charge and correlates the experimental points and the output of the network, so that ANFIS error in some states of charge is less than 2%.

Keywords Lithium-ion Battery; State of Charge; Battery Management System; ANFI; ANN

CITATION LINKS

[1] Technology Perspectives--scenarios and strategies to 2050 [2] Hybrid electric vehicles and their challenges: A review [3] On-line remaining energy prediction: A case study in embedded battery management system [4] Battery-Management System (BMS) and SOC development for electrical vehicles [5] Capacity fade diagnosis of Lithium ion battery pack in electric vehicle base on fuzzy neural network [6] SoC estimation of Lithium battery based on improved BP neural network [7] State of charge and state of health estimation for lithium batteries using recurrent neural networks [8] Battery state of charge estimation using an Artificial Neural Network. 2017 IEEE Transportation Electrification Conference and Expo (ITEC) [9] An improved SoC estimation algorithm based on artificial neural network [10] ANFIS and ICA trained neural network modeling of Ni-Cd batteries using experimental data [11] A fuzzy logic-based model for Li-ion battery with SOC and temperature effect. 11th IEEE International Conference on Control & Automation (ICCA) [12] State-of-charge estimation of VRLA batteries using neural networks and extended kalman filter [13] Battery state of charge estimation using a load-classifying neural network [14] Capacity fade estimation in electric vehicle Li-ion batteries using artificial neural networks [15] A merged fuzzy neural network and its applications in battery state-of-charge estimation [16] Lithium-ion battery state of charge estimation based on square-root unscented Kalman filter [17] State-of-charge estimation for Lithium-ion batteries using neural networks and EKF [18] State of charge estimation of power Li-ion batteries using a hybrid estimation algorithm based on UKF [19] State of charge estimation of lead acid batteries using neural network [20] Accurate electrical battery model capable of predicting runtime and I-V performance [21] An algorithm for least-squares estimation of nonlinear parameters [22] Battery management systems in electric and hybrid vehicles [23] A new method in determining, rotor crack depth by using multi-scale permutation Entropy and ANFIS network [24] Accuracy improvement of SOC estimation in lithium-ion batteries [25] The SOC estimation of power Li-Ion battery based on ANFIS model

¹Automotive Department, Mechanical Engineering Faculty, Shahid Rajaee Teacher Training University, Tehran, Iran

*Correspondence

Address: Automotive Department, Mechanical Engineering Faculty, Shahid Rajaee Teacher Training University, Tehran, Iran. Postal Code: 1664867773
Phone: +98 (21) 76297021
Fax: +98 (21) 76297021
mnouri@sru.ac.ir

Article History

Received: March 25, 2018
Accepted: September 17, 2018
ePublished: January 1, 2019

مقایسه تخمین حالت شارژ باتری لیتیوم یون با استفاده از شبکه عصبی مصنوعی و استنتاج عصبی- فازی- تطبیقی

مهرداد نوری خاجوی * PhD

گروه مکانیک خودرو، دانشکده مهندسی مکانیک، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران
غلامرضا بیات MSC
گروه مکانیک خودرو، دانشکده مهندسی مکانیک، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران

چکیده

تخمین دقیق حالت شارژ یک باتری نه تنها برای مدیریت بهینه انرژی در خودروهای الکتریکی و شبکه‌های هوشمند قدرت، بلکه برای حفاظت باتری از رفتن به شرایط تخلیه عمیق یا شارژ بیش از اندازه و در نتیجه کاهش عمر باتری ضروری است. این شرایط حتی ممکن است شرایط بالقوه خطرناکی به لحاظ انفجار باتری ایجاد کند. با وجود اهمیت بسیار زیاد پارامتر حالت شارژ، این پارامتر به‌طور مستقیم از پایانه‌های باتری قابل اندازه‌گیری نیست. در این پژوهش ابتدا مدل مدار معادل الکتریکی در محیط سیمولینک متلب با دو شبکه RC شبیه‌سازی شده است. این مدل دارای این مزیت است که یک آزمون سریع برای استخراج پارامترها و مشخصات دینامیکی مدل باتری را ارائه می‌کند ولی برای کاربرد برخط در خودرو مناسب نیست. به همین دلیل است که الگوریتم‌های شبکه عصبی و استنتاج فازی عصبی سازگار برای تخمین حالت شارژ بسته باتری و سلول منفرد براساس داده‌های اندازه‌گیری شده برای هر سلول به‌طور مجزا مورد نیاز است. در این پژوهش به منظور اعتبارسنجی شبکه عصبی از نرخ جریان ۰/۱۶ آمپر و در شبکه انفیس از نرخ تخلیه ۰/۸، ۰/۱ و ۰/۴۵ استفاده شده است. مقایسه روش انفیس با روش عصبی در این تحقیق نشان داد که روش انفیس در تخمین حالت شارژ از شبکه عصبی دقیق‌تر است و دارای همبستگی نقاط تجربی و خروجی شبکه است، به طوری که خطای شبکه انفیس در برخی حالت‌های شارژ به مقدار کمتر از ۲٪ می‌رسد.

کلیدواژه‌ها: باتری لیتیوم یون، حالت شارژ باتری، سیستم مدیریت باتری، استنتاج عصبی- فازی- تطبیقی، شبکه عصبی مصنوعی

تاریخ دریافت: ۹۷/۰۱/۰۵

تاریخ پذیرش: ۹۷/۰۶/۲۶

* نویسنده مسئول: mnouri@srui.ac.ir

۱- مقدمه

آژانس بین المللی انرژی در سال ۲۰۱۰ با ارائه نقشه راه تا سال ۲۰۵۰ [1] محدودیت‌هایی را برای بخش‌های تولیدکننده دی‌اکسیدکربن به‌خصوص بخش‌های ساختمان، حمل‌ونقل، صنعت و تولید برق تعریف کرد. در ضمن جهان در حال حرکت به سوی عواقب خطرناک مانند گرم‌شدن کره زمین و انتشار گازهای گلخانه‌ای ناشی از استفاده گسترده از سوخت‌های فسیلی مختلف از جمله دیزل و بنزین در وسایل نقلیه است که سالانه مقدار زیادی دی‌اکسیدکربن تولید می‌کند [2]. بنابراین باتری با فناوری پیشرفته، یک عنصر کلیدی در بسیاری از کاربردها مانند وسایل الکتریکی، وسایل نقلیه برقی، اجزای سیستم‌های ماهواره و سیستم‌های قدرت است. باتری لیتیوم یون به دلیل چگالی انرژی بالا، میزان تخلیه خودبه‌خودی بسیار کم و طول عمر زیاد نسبت به انواع دیگر باتری‌ها، یک فناوری جدید و امیدبخش در خودروهای برقی و ترکیبی برقی و سوخت‌های فسیلی محسوب می‌شود [3]. با این حال، شارژ و تخلیه بیش از اندازه باتری‌های لیتیوم یون نیز می‌تواند صدمات بازگشت‌ناپذیری به سلول‌های باتری وارد نماید و کارایی و طول عمر آن را کاهش دهد. علاوه بر این در بسیاری از برنامه‌های کاربردی، تخمین دقیق انرژی موجود در باتری در زمان

استفاده و کارکرد، برای عملکرد مناسب کل سیستم مانند مدیریت باتری لازم و ضروری است. بنابراین یک الگوریتم تخمین قابل اعتماد و دقیق حالت شارژ باتری‌های لیتیوم یون در سیستم مدیریت باتری خودروی الکتریکی EV، HEV و PHEV لازم است تا کاربر بتواند مدت‌زمان و چگونگی استفاده باتری را قبل از توقف باتری و در نتیجه توقف خودرو تشخیص دهد [4]. لی و همکاران [5] تشخیص ظرفیت باتری لیتیوم یون خودروی برقی را براساس شبکه عصبی فازی توسعه دادند. در این پژوهش، معادله‌ای برای توصیف رفتار دینامیک باتری با توجه به تغییرات جریان و حالت شارژ باتری ارائه شده است. روش شمارش جریان کولمب متکی بر جمع جریان باتری نسبت به زمان است و این روش در تخمین حالت شارژ باتری توسط اکثر تولیدکنندگان سیستم مدیریت باتری به دلیل سادگی و سهولت اجرای آن ترجیح داده شده است. با این حال، این روش به دلایل متعددی دقیق نیست و فرضیه روش بدین صورت است که تمام سلول‌ها در حال تعادل هستند و در این روش بالانس بودن از تأثیر بسیار بالایی برخوردار است. در واقع سلول‌های باتری معمولاً دارای سطوح مختلف ولتاژ و دما در تمام حالت‌های کارکرد هستند که باعث می‌شود حالت شارژ (SOC) هر یک از سلول‌ها متفاوت باشند. گو و همکاران [6] تخمین حالت شارژ باتری لیتیوم یون را براساس شبکه عصبی پایه شعاعی ارائه نمودند. نتایج نشان داد که اندازه‌گیری ولتاژ، جریان و درجه حرارت و مقاومت داخلی به‌عنوان ورودی شبکه عصبی برای تخمین باقیمانده توان باتری دارای سرعت بالاتر و محدوده کار وسیع‌تر است. داده‌های تجربی استخراج‌شده از تست تخلیه 1C ثابت برای اعتبارسنجی و آموزش شبکه عصبی استفاده شده است. چائویی و همکاران [7] شبکه عصبی را به‌منظور تخمین برخط حالت شارژ باتری لیتیوم یون به کار برده‌اند، زیرا روش خارج از خط در مورد باتری لیتیوم یون که رابطه ولتاژ مدار باز و حالت شارژ دارای پروفیل تخت بوده، دقت لازم را نداشته است یا پاسخگو نیست. این پژوهشگران نشان داده‌اند که این روش تخمین مانند سایر استراتژی‌های تخمین نیاز به شناسایی پارامترهای پیچیده و مدل ریاضی ندارد. نتایج آنها نشان می‌دهد که تخمین با در نظر گرفتن دمای باتری و فرسودگی، دقیق‌تر و برجسته‌تر خواهد بود. ولتاژ مدار باز باتری را می‌توان در طول زمان استراحت باتری حین شارژ و تخلیه اندازه‌گیری کرد و ارتباط بین ولتاژ مدار باز OCV و SOC را برای تخمین حالت شارژ به کار برد. اسماعیل و همکاران [8] حالت شارژ باتری لیتیوم یون خودروی برقی را با استفاده از شبکه عصبی مصنوعی محاسبه نموده‌اند. این محققان نشان دادند که اگر شبکه عصبی NARX درست آموزش ببیند، قادر است ویژگی‌های غیرخطی باتری را محاسبه نماید و پارامترهای غیرقابل اندازه‌گیری از جمله SOC را با استفاده از پارامترهای قابل اندازه‌گیری جریان و ولتاژ ارائه نماید. داده‌های تجربی مورد استفاده در مطالعه این محققان از باتری لیتیوم یون 3.6V و ظرفیت آن 3.4Ah به دست آمده و خطای متوسط مربعات 3.853×10^{-9} در تست چرخه رانندگی شهری است.

لیو و همکاران [9] الگوریتم تخمین حالت شارژ باتری را براساس شبکه عصبی با پالس جریان دینامیک ارائه نموده‌اند. این محققان الگوریتم تصحیح ولتاژ را به‌منظور بهبود تخمین و کاهش مشکلات مربوط به روش مرسوم شبکه عصبی و ماشین بردار پشتیبان ارائه کرده‌اند. میانگین خطای مربعات در روش مرسوم حدود ۲/۱۴٪ به دست آمده و نتیجه پس از آموزش شبکه عصبی ۲/۵٪ شده است. سروی و همکاران [10] به‌منظور ارائه مدل دقیق‌تر و تخمین درست

۲ است را در تخمین بسته باتری ۳۲۰ سلولی ارایه کرده است که از آن روش بیشتر در شناسایی پارامترهای مدل استفاده می‌شود. سپس الگوریتم تخمین هیبریدی برای تخمین حالت شارژ بسته باتری تحت سیکل رانندگی اروپایی استفاده شده است. نتیجه نشان می‌دهد که خطای الگوریتم تخمین هیبرید کمتر از ۵٪ است. *آناند و مادورا*^[۱۹] حالت شارژ باتری سرب اسید را با استفاده از شبکه عصبی و انفیس تخمین زدند. ولتاژ، چگالی اسید و جریان برای ورودی شبکه عصبی و حالت شارژ خروجی فرض شده است و نشان دادند که دقت شبکه انفیس با در نظر گرفتن چگالی ویژه اسید بهبود یافته است. در این پژوهش ابتدا شبکه عصبی پرسپترون چندلایه با الگوریتم پس‌انتشار خطا به منظور تخمین باتری با چگالی انرژی بالاتر استفاده می‌شود. با آزمون سعی و خطا تعداد ۹ نوروں در لایه پنهان انتخاب شده است که کمترین مقدار خطا را ارایه می‌دهد. سپس شبکه انفیس برای تخمین حالت شارژ و مقایسه با خطای شبکه عصبی به کار برده شده است که نتایج بهبود تخمین انفیس را نسبت به شبکه عصبی نشان داد و طبق یافته‌ها مقدار میانگین مربعات خطا در روش انفیس (ANFIS) کاهش یافته است و می‌تواند به عنوان تخمین‌گر دقیق‌تر، رابطه حالت شارژ و ولتاژ مدار باز را ارایه دهد.

۱-۱- مدل مدار معادل الکتریکی سلول باتری

یکی از فناوری‌های کلیدی در سیستم مدیریت باتری خودروهای برقی و ترکیبی با دو حالت برقی و سوخت فسیلی، نظارت دقیق بر وضعیت شارژ SOC باتری است. حالت شارژ باتری به عنوان ظرفیت آمپر ساعت موجود باتری است و به صورت درصدی از ظرفیت فعلی آن تعریف می‌شود:


(۱)

$$SOC = SOC_0 + \frac{\int_{t_0}^T I(t)dt}{C_n}$$


در معادله نشان داده شده فوق، SOC حالت شارژ فعلی باتری بر حسب آمپر ساعت و SOC_0 حالت شارژ تخمین زده شده اولیه قبل از شارژ یا تخلیه باتری و C_n ظرفیت اسمی باتری و $\int_{t_0}^T I(t)dt$ مجموع جریان شارژ یا تخلیه باتری است. به عنوان مثال اگر جریان ۲ آمپر به مدت ۳ ساعت به باتری وارد شود، مقدار ۶ آمپر ساعت به شارژ باتری افزوده خواهد شد. اگر ظرفیت اسمی باتری ۲۴ آمپر ساعت باشد، به SOC باتری، ۲۵٪ افزوده خواهد شد. مدل‌ها و دقت‌های مختلفی از مدار معادل الکتریکی برای پیش‌بینی رفتار باتری وجود دارد. چن و رینکن-مور^[۲۰] دو گروه RC یا به عبارتی مدل مرتبه ۲ را به عنوان مدل دقیق مدل‌سازی باتری توصیه می‌کنند که این مدل جامع، دقیق و دارای سادگی نسبی بوده که در شکل ۱ نشان داده شده است. مدل ارایه شده توسط این محققان خطای ولتاژ ۳۰mV را در محدوده حالت شارژ ۱۰ تا ۱۰۰٪ نشان می‌دهد. این مدل مدار معادل الکتریکی به صورت شکل ۲ نشان داده شده است که در محیط نرم‌افزار MATLAB شبیه‌سازی شد و با نرخ‌های مختلف تخلیه، رفتار دینامیک غیرخطی باتری یعنی رابطه ولتاژ مدار باز و حالت شارژ باتری به صورت نمودار ۱ به دست آمده است. معادلات ۲ تا ۷ رابطه پارامترهای مدل باتری در مدل‌سازی مدار معادل الکتریکی بوده که در شبیه‌سازی MATLAB در بلوک مدل باتری شکل ۲ مدل شده است. $V_{OC}(SOC)$ ولتاژ مدار باز، ولتاژ ترمینال باتری است که باتری از نظر فعل و انفعالات شیمیایی به تعادل داخلی رسیده و بار و جریان شارژ و تخلیه روی باتری اعمال نشده است، اندازه‌گیری

ولتاژ باتری در شرایط شارژ، سه روش مدل‌سازی غیرخطی به نام منطق فازی، سیستم استنتاج فازی و الگوریتم رقابتی مدل‌سازی باتری نیکل کادمیم را ارایه نموده‌اند. ورودی‌های شبکه، جریان و زمان انتخاب شده است. جیانی و همکاران^[۱۱] مدل براساس منطق فازی برای باتری لیتیوم یون را به منظور تخمین حالت شارژ و با تاثیر دما به کار بردند، زیرا مدار معادل الکتریکی به ندرت مدل دمایی را ارایه می‌کند. داده‌های تجربی از باتری ۲/۶ آمپر ساعت با دستگاه ARBIN 2000 و به روش پالسی با نرخ تخلیه ۰/۱ ظرفیت اسمی با استراحت ۲۰ دقیقه استخراج شده است. نتایج بیشترین خطا ۲/۱۲٪ و خطای ولتاژ ۱۱mV نشان می‌دهد. شهریار و فرخی^[۱۲] تخمین حالت شارژ باتری سرب اسید ۲/۵ آمپر ساعت ۲۷ را با استفاده از شبکه عصبی پایه تابع شعاعی و فیلتر کالمن توسعه یافته ارایه نموده‌اند. ورودی شبکه عصبی شامل ولتاژ پایانه باتری، جریان و حالت شارژ در زمان نمونه‌برداری فعلی بوده و خروجی شبکه ولتاژ پایانه باتری در زمان نمونه‌برداری بعدی است. سپس حالت شارژ در دو حالت شارژ و تخلیه به دلیل رفتار متفاوت در دو حالت با دو شبکه عصبی تخمین زده شده است. تانگ و همکاران^[۱۳] تخمین حالت شارژ باتری لیتیوم یون را با استفاده از روش شبکه عصبی طبقه‌بندی بار ارایه نمودند. در این نوع تخمین، پیش‌پردازش روی ورودی باتری و طبقه‌بندی در سه حالت بدون بار، حالت شارژ و تخلیه با سه شبکه عصبی به صورت موازی انجام می‌شود. با استفاده از پروفیل چرخه رانندگی خودرو برای آموزش مدل و چرخه پالسی برای اعتبارسنجی، روش پیشنهادی خطای تخمینی میانگین ۳/۸٪ را نشان می‌دهد. این نتایج نشان می‌دهد که روش یادگیری ماشین با استفاده از داده‌ها می‌تواند عملکرد تخمین مناسب را در مقایسه با سایر مشاهده‌گرها ارایه کند. حسین^[۱۴] مدل هوش مصنوعی را برای تخمین ظرفیت باقیمانده و سطح شارژ باتری‌های لیتیوم یون مورد استفاده در خودروی برقی ارایه نموده است. دو ساختار متفاوت از شبکه‌های عصبی مصنوعی براساس داده‌های جمع‌آوری شده از ۴۸۰ سیکل شارژ و تخلیه برای ارزیابی محوشدگی ظرفیت و SOC باتری‌های لیتیوم یونی آموزش داده شده و باتری مورد استفاده برای استخراج داده‌های آموزش لیتیوم-یون ۳/۶۷ و ظرفیت ۱۶/۵ آمپر ساعت به کار گرفته شده است. تکنیک به کار گرفته شده توسط این محققان دقت بالا را در تخمین حالت شارژ نشان می‌دهد، زیرا از روش پس‌خورد استفاده شده است. منطق فازی، شبکه‌های عصبی و الگوریتم‌های ژنتیکی نیز برای تخمین SOC باتری ترکیب شده‌اند. لی و همکاران^[۱۵] تعدادی از شبکه‌های عصبی فازی کوچک را به ساختار یادگیری زنجیره‌ای ترکیب نمودند تا مشکل تعداد زیاد ورودی‌ها حل شود. الگوریتم‌های ژنتیکی برای تنظیم پارامترهای ورودی کنترل و وزن‌های شبکه عصبی مصنوعی استفاده شده است، در صورتی که داده‌های تجربی برای آموزش استفاده می‌شوند. نتایج تجربی این محققان نشان می‌دهد که توانایی یادگیری مدل پیشنهادی این مطالعه که ترکیبی از مدل فازی عصبی و ژنتیک بوده، از مدل یادگیری پس‌انتشار عصبی بهتر است. ترکیبی از شبکه عصبی مصنوعی و فیلتر کالمن توسعه یافته نیز به منظور تخمین حالت شارژ باتری‌های لیتیوم یون که در آن شبکه‌های عصبی مبتنی بر پایه شعاعی و شبکه پیش‌خور استفاده شده، توسط قلیزاده-نارم و همکاران^[۱۶] و همچنین چرخ‌گرد و همکاران^[۱۷] اجرا شده است. شبکه عصبی مصنوعی در آزمایش‌های انجام شده در حالت برون خط آموزش داده می‌شود. دانگ^[۱۸] الگوریتم تخمین ترکیبی فیلتر کالمن بی‌رد و روش ولتاژ مدار باز که مدل معادل الکتریکی مرتبه


می‌شود و با حالت شارژ به صورت تابع $g(x_1)$ رابطه دارد و $R_{Series}(SOC)$ ، مقاومت داخلی، $R_{Transient-S}(SOC)$ و $R_{Transient-L}(SOC)$ مقاومت گذرا و همچنین (SOC) و $C_{Transient-L}(SOC)$ خازن حالت گذرا مربوط به ثابت زمانی کوتاه و بلند را نشان می‌دهد.



شکل (۱) مدل مدار معادل الکتریکی باتری



شکل (۲) مدل‌سازی سلول باتری با استفاده از شبیه‌سازی در محیط MATLAB



نمودار (۱) پاسخ ولتاژ مدار باز OCV بر حسب SOC باتری با نرخ‌های مختلف تخلیه در شبیه‌ساز MATLAB

منظور از نرخ جریان 1C جریان ثابت ایده‌آلی است که باتری را در مدت یک ساعت کاملاً شارژ یا تخلیه می‌کند. جریان 0.5C و 2C به ترتیب در طول مدت ۲ ساعت و نیم‌ساعت باتری را کاملاً شارژ یا تخلیه می‌کند. برای شبیه‌سازی از معادلات ۲ تا ۷ در MATLAB استفاده شده است [20].

(۲)

$$V_{OC}(SOC) = -1.031 \cdot e^{-35 \cdot SOC} + 3.685 + 0.2156 \cdot SOC - 0.1178 \cdot SOC^2 + 0.3201 \cdot SOC^3$$

(۳)

$$R_{Series}(SOC) = 0.1562 \cdot e^{-24.37 \cdot SOC} + 0.07446$$

(۴)

$$R_{Transient-S}(SOC) = 0.3208 \cdot e^{-29.14 \cdot SOC} + 0.04669$$

(۵)

$$C_{Transient-S}(SOC) = -752.9 \cdot e^{-13.51 \cdot SOC} + 703.6$$

۲- طراحی شبکه عصبی مصنوعی


۲-۱- نحوه انجام آزمایش و جمع‌آوری داده‌ها

باتری انتخاب‌شده در این پژوهش، مورد استفاده خودروهای برقی بوده و مشخصات این نوع باتری در جدول ۱ آمده است. بخش ابتدای این مطالعه، تخمین حالت شارژ باتری با استفاده از شبکه عصبی مصنوعی است.

جدول (۱) مشخصات باتری خودرو برقی مورد آزمون

شماره	پارامترهای باتری	مقادیر پارامترها
۱	نوع باتری	1400A-h-3.3v-18650
۲	ظرفیت اسمی باتری	۱/۴A-h
۳	کمترین ظرفیت	۱/۳۵A-h
۴	ولتاژ خالص باتری	۳/۳v
۵	بیشترین ولتاژ شارژ	۳/۶v
۶	حالت شارژ	جریان ثابت/ولتاژ ثابت
۷	زمان شارژ	۶hours
۸	بیشترین جریان تخلیه	۳C
۹	ولتاژ قطع تخلیه	۲/۵v

در بخش دوم با استفاده از شبکه انفیسی تخمین حالت شارژ انجام خواهد شد و با نتایج تخمین‌گر عصبی مقایسه می‌شود. داده‌های تست شامل سه پارامتر جریان، ولتاژ و حالت شارژ باتری حاصل از آزمون عملی خودروهای برقی طبق روش USABC با نرخ جریان تخلیه ثابت به دست آمده است تا همبستگی بین ولتاژ ترمینال باتری و حالت شارژ بررسی شود. داده‌های به‌دست‌آمده از آزمون که در طراحی شبکه عصبی و انفیسی استفاده شده است، در دمای ثابت 23°C با نرخ تخلیه ۰/۹، ۰/۸، ۰/۷، ۰/۱ تا ۰/۱ آمپر را شامل می‌شود. داده‌های تست به دو بخش داده‌های آموزش (نمودار ۲) و اعتبارسنجی شبکه عصبی ۰/۶ آمپر و انفیسی با نرخ تخلیه ۰/۴۵، ۰/۸ و ۰/۱ طبقه‌بندی شده است.




نمودار (۲) منحنی داده‌های تجربی تست با نرخ مختلف تخلیه باتری


۲-۲- ساختار شبکه عصبی مصنوعی

شبکه عصبی مصنوعی به‌طور گسترده در تخمین سیستم‌های غیرخطی به کار رفته و به دلیل مزیت‌های بی‌شمار این نوع تخمین‌گرها از جمله دقت زیاد، قیمت و زمان کم کاربرد فراوان یافته است. مغز انسان، ایده اصلی شبکه عصبی مصنوعی بوده که

Y_{ex} خروجی، Y_{pre} خروجی شبکه و N تعداد نقاط داده‌ها است. برای دستیابی به یک شبکه بهینه، تعداد نورون‌ها در لایه‌های پنهان تغییر کرده و عملکرد شبکه محاسبه شده است. عملکرد کلی، آموزش، اعتبارسنجی و عملکرد تست هر شبکه در برابر عدد نورون در نمودار ۳ گزارش شده است. با تغییر تعداد نورون‌های لایه میانی می‌توان مشاهده کرد که شبکه عصبی با ۹ نورون در لایه‌های پنهان دارای حداقل میانگین مربعات خطا بوده، بنابراین تعداد ۹ نورون در این پژوهش انتخاب شده است. شبکه عصبی با تعداد ۱۰۰ نورون در لایه پنهان و تعداد لایه‌های بیشتر نیز تست شد که تغییر زیادی نداشت و مقدار MSE برابر ۰/۰۰۴۴ حاصل شد.



عملکرد الگوریتم پیشنهاد شده در جست‌وجوی شبکه عصبی در نمودار ۴ نشان داده شده است. دایره، نشان‌دهنده زمانی است که شبکه عصبی بیشترین تعمیم‌پذیری را دارد.



نمودار ۴) نمودار بهترین عملکرد شبکه عصبی

این شبکه عصبی از نوع پرسپترون چندلایه بوده و تابع بهینه‌سازی مجموع مربعات خطا از نوع الگوریتم لونیگ-مارکوات است. این الگوریتم به زمان کمتری برای همگرایی نیاز دارد و آموزش به‌طور خودکار زمانی که الگوریتم به‌طور کلی بهبود یابد و خطا کاهش یابد، متوقف می‌شود.

برای ارزیابی صحت شبکه عصبی و تجزیه و تحلیل انحراف از حالت شارژ باتری استفاده شده است. انحراف داده‌های تجربی و خروجی شبکه عصبی به‌صورت معادله ۱۱ بیان می‌شود.

$$\text{Margin of deviation} = \left[\frac{(\text{SOC})_{\text{Exp}} - (\text{SOC})_{\text{ANN}}}{(\text{SOC})_{\text{Exp}}} \right] \times 100$$

یک شبکه پردازش موازی برای تعیین رابطه غیرخطی پیچیده بین متغیرهای ورودی و متغیرهای خروجی است. ساختار شبکه عصبی مصنوعی، ارتباط بین نورون‌ها و لایه‌ها را ارائه می‌دهد. وزن و بایاس روی ارتباطات با استفاده از الگوریتم یادگیری تعیین می‌شود. شبکه عصبی مصنوعی شامل یک لایه خروجی و یک لایه پنهان است. در این مطالعه، تابع انتقال لایه پنهان به‌عنوان تانژانت سیگموئید در نظر گرفته شده است، در حالی که عملکرد خطی خالص برای لایه خروجی مورد استفاده قرار می‌گیرد. معادله ۸ عملکرد انتقال تانژانت سیگموئید را به‌صورت زیر ارائه می‌دهد:


$$f(x) = \frac{1}{1 + \exp(-x)}$$

از آنجایی که الگوریتم لونیگ-مارکوات به‌طور کلی منجر به خروجی‌های بهتر شبکه عصبی می‌شود [21]، بنابراین الگوریتم لونیگ-مارکوات در شبکه عصبی برای مدل‌سازی رفتار باتری مورد استفاده قرار گرفته است. در این مطالعه، یک شبکه پیش‌خور با ۹ نورون در لایه پنهان استفاده شده است (شکل ۳).

دو پارامتر ورودی شامل ولتاژ و جریان و یک خروجی به‌صورت حالت شارژ باتری همانند یک مطالعه [8] در این تحقیق استفاده شده که حداقل پارامترهای لازم در BMS خودروی برقی و هایبرید است [22]. داده‌های مربوط به حالت شارژ باتری مطابق رابطه ۹ نرمالیزه شده است. داده‌های تجربی تست سلول در منحنی نمودار ۲ ارائه شده که نقاط نشان‌دهنده ولتاژ پایانه باتری در هر حالت شارژ بعد استراحت سلول بوده و برابر با ولتاژ مدار باز باتری است. به‌عنوان مثال بعد از ۱۰۰٪ شارژ از ۱۰۰٪ به صفر کاهش می‌یابد و باتری کاملاً تخلیه می‌شود.

(۹)


$$X_{\text{norm}} = 2 \times \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} - 1$$



شکل ۳) ساختار شبکه عصبی

معیار انتخاب یک شبکه مناسب، براساس عملکرد و اجتناب از برازش بیش از حد است. عملکرد شبکه عصبی مصنوعی به‌معنی کمترین مربعات خطا (MSE) است و توسط معادله ۱۰ در زیر بیان می‌شود:



$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (Y_{\text{pre}} - Y_{\text{ex}})^2$$




جدول ۲) مقایسه تابع هدف و خروجی شبکه عصبی ارایه شده (جریان ۰/۶ آمپر)

حالت شارژ هدف	۰	۱۰	۲۰	۳۰	۴۰	۵۰	۶۰	۷۰	۸۰	۹۰	۱۰۰	
تخمین حالت شارژ	-	۰	۱۴	۲۰	۲۹	۳۹/۵	۴۷	۵۷	۶۶	۷۶	۹۱	۱۰۲
خطای تخمین (%)	-	۰	۴۰	۳/۳۳	۱/۲۵	۶	۵	۵/۷۱	۵	۱/۱۱	۲	-


در ادامه برای تست شبکه عصبی پیشرو، جریان و حالت شارژ باتری به عنوان ورودی به شبکه عصبی داده شد. با انتخاب الگوریتم آموزش لوبزبرگ-مارکوات شبکه آموزش دیده و خروجی، تخمین ولتاژ ترمینال باتری در نظر گرفته و نتایج تخمین ولتاژ ترمینال باتری در نمودار ۹ ارایه شده است که بهترین عملکرد اعتبارسنجی شبکه عصبی ارایه شده دارای مقدار خطای 0.00055538 است. نمودار ۱۰ رگرسیون شبکه عصبی با مقدار ضریب همبستگی اعتبارسنجی 0.99443 را نشان می‌دهد.




هیستوگرام حاشیه انحراف شبکه عصبی مطلوب در نمودار ۵ نمایش داده شده است. همان طور که دیده می‌شود توزیع انحراف در اطراف صفر متمرکز شده است، به این معنی که شبکه عصبی مصنوعی دقت قابل قبول مطلوبی را دارد. مجموعه داده‌های تجربی به دست آمده برای آموزش، اعتبارسنجی و آزمون شامل به ترتیب ۷۰، ۱۵ و ۱۵٪ نقاط از کل داده‌های آزمون هستند که نتایج در نمودار ۶ ارایه شده است. هنگامی که وزن‌های شبکه مشخص شدند، به منظور اعتبارسنجی از شبکه عصبی آموزش دیده شده، استفاده و منحنی با نرخ تخلیه 0.06 آمپر از تخمین شبکه عصبی و داده‌های تجربی تست باتری مقایسه شد (نمودارهای ۷ و ۸). جدول ۲ مقادیر حالت شارژ هدف و مقدار تخمین شبکه عصبی را ارایه می‌دهد که پس از مقایسه مقدار خطا در سطر سوم جدول محاسبه شده است.



نمودار ۵) پیشینه نمای خطای شبکه عصبی (هیستوگرام)



نمودار ۶) نتایج آموزش، اعتبارسنجی و آزمون شبکه عصبی



نمودار ۷) مقادیر خطای شبکه عصبی در تمام داده‌های تجربی

(۱۴)

Rule 1: If x is A_1 and y is B_1 , then f_1
 $= p_1x + q_1y + r_1$


(۱۵)

Rule 1: If x is A_2 and y is B_2 , then f_2
 $= p_2x + q_2y + r_2$

(۱۶)


$$F = \frac{w_1f_1 + w_2f_2}{w_1 + w_2} = \bar{w}_1f_1 + \bar{w}_2f_2$$

در معادلات فوق x, y ورودی سیستم، $A_{1,2}$ و $B_{1,2}$ تنظیمات فازی بوده و f_1 و f_2 خروجی در ناحیه فازی مشخص شده توسط قانون فازی است. p_1, q_1, r_1 پارامترهای تطبیقی خطی هستند که حین فرآیند آموزش تعیین می‌شوند. شبکه‌ای که از این طریق به دست می‌آید، می‌تواند روش‌های یادگیری شبکه‌های عصبی را به‌منظور آموزش پارامترهای خود به کار گیرد. به‌علاوه ساختار حاصل از این طریق به‌صورت یک سیستم جعبه سیاه باقی نمی‌ماند و با توجه به قابلیت تفسیرپذیری سیستم‌های فازی مزایای بیشتری خواهد داشت و نتیجه نهایی به فرم قواعد زبانی قابل بیان خواهد بود. شکل ۵ رابطه میان توابع عضویت و قوانین شبکه فازی و عملکرد آن را نشان می‌دهد [23].



شکل ۵) عملکرد شبکه انفیس

بنابراین پس از مشخص شدن ساختار شبکه عصبی فازی سازگار مطابق قوانین بیان شده، ساختار انفیس در نرم‌افزار MATLAB طراحی شد و داده‌های باتری شامل ولتاژ، جریان و حالت شارژ به شبکه داده شد و پس از آموزش شبکه انفیس، خروجی شبکه و داده‌های تجربی با یکدیگر مقایسه شدند که منحنی مقایسه در نمودار ۱۱ برای نرخ‌های جریان تخلیه باتری ۰/۱ و ۰/۸ آمپر آمده و سپس برای نرخ تخلیه باتری با نرخ ۰/۴۵ آمپر اعتبارسنجی شبکه آزمایش شده است تا همبستگی نقاط و منحنی نسبت به مقادیر داده‌های موجود دیگر نرخ‌های جریان مورد آزمون قرار گیرد. جداول ۳ و ۴ مقادیر حالت شارژ هدف که از خروجی انفیس به دست می‌آید و مقدار واقعی را ارائه می‌دهد.




نمودار ۱۱) مقایسه مقادیر هدف انفیس و داده تجربی برای جریان تخلیه مختلف

۳- شبکه استنتاج عصبی- فازی سازگار

شبکه انفیس یک مدل استنتاج فازی در چهارچوب شبکه‌های فازی چندلایه و نیز یک مدل سوگنوی فازی است که در چهارچوب سیستم‌های تطبیقی برای تسهیل یادگیری و سازگاری با سیستم مورد استفاده قرار می‌گیرد. ساختار شبکه‌های فازی در دو حالت ممدانی و سوگنو ایجاد می‌شود. اگر قوانین شرطی سازنده شبکه فازی در مقدم و تالی به‌صورت جملات فازی بیان شده باشد، شبکه فازی ممدانی ایجاد می‌شود.

ساختار انفیس به شکل قوانین اگر- آن گاه به‌صورت شکل ۴ ارائه می‌شود که دایره‌ها نشان‌دهنده گره‌های ثابت شبکه و مربع‌ها نشان‌دهنده گره‌های تطبیقی هستند. در لایه اول گره‌ها به‌صورت تطبیقی بوده است و به‌عنوان لایه فازی سازی در نظر گرفته می‌شود. خروجی لایه اول به‌صورت توابع عضویت از ورودی‌ها است و مقدار عضویت هر ویژگی از رابطه ۱۲ محاسبه می‌شود. فرض کنید شبکه عصبی فازی دارای دو ورودی x و y و یک خروجی F است.



شکل ۱۴) ساختار شبکه عصبی- فازی- تطبیقی

برای مدل فازی سوگنوی مرتبه اول با تابع عضویت نوع گوسی قوانین زیر برقرار است که در این پژوهش نیز استفاده شد:

(۱۲)

$$\begin{cases} o_{1,i} = \mu_{A_i}(x), i = 1,2 \\ o_{2,i} = \mu_{B_i}(y), i = 1,2 \end{cases}$$

$o_{1,i}$ خروجی تابع عضویت تعریف شده در لایه اول است و μ یک تابع عضویت بوده و باید حقیقی و پیوسته باشد. لایه دوم لایه استنتاج فازی است. در این لایه با توجه به عملکرد عطف مابین جملات مقدم قوانین، ارزش مقدم هر رابطه با ضرب مقدار عضویت مجموعه‌ها محاسبه می‌شود که در رابطه ۱۳ نشان داده شده است.

(۱۳)

$$w_i = \mu_{A_i}(x)\mu_{B_i}(y), i = 1,2$$

لایه سوم، خروجی لایه دوم را به شکل نرمالیزه تبدیل می‌نماید. در لایه چهارم گره‌ها به‌صورت سازگار هستند و خروجی هر گره در این لایه به‌صورت چندجمله‌ای مرتبه اول از مدل سوگنو خواهد بود. در این لایه، یک ترکیب خطی بین ورودی‌ها و وزن‌های به‌دست آمده محاسبه شده است و به خروجی می‌رود (رابطه ۱۴ و ۱۵).

در لایه پنجم فقط یک گره ثابت وجود دارد که این گره ثابت شامل مجموع همه سیگنال‌های ورودی است. در این لایه جمع خروجی‌های لایه چهارم از رابطه ۱۶ به دست می‌آید.


شبکه‌های عصبی و سیستم‌های فازی، تخمین‌گرهای مستقل از مدل هستند و قابلیت‌های مشابهی را در برخورد با عدم قطعیت‌ها و نویز از خود نشان می‌دهند. لذا امکان تبدیل کردن سیستم استنتاج فازی به فرم یک شبکه آموزش‌پذیر وجود دارد [21].

جدول ۳) مقایسه تابع هدف و خروجی شبکه انفیس با نرخ جریان (۰/۱ آمپر)


حالت شارژ هدف	۱۰۰	۹۰	۸۰	۷۰	۶۰	۵۰	۴۰	۳۰	۲۰	۱۰
تخمین حالت شارژ	۱۰۰	۸۸/۲۸	۸۲/۲۹	۷۰/۲۵	۵۳/۵۵	۵۳/۵۵	۴۲/۱۴	۳۰/۱۳	۱۹/۷۷	۰
خطای تخمین (%)	۰	۱/۹۱	۲/۸۶	۰/۳۶	۵/۹۱	۷/۱	۵/۳۵	۰/۴۳	۱/۱۵	-

جدول ۴) مقایسه تابع هدف و خروجی شبکه انفیس ارایه شده (جریان ۰/۸ آمپر)


حالت شارژ هدف	۱۰۰	۹۰	۸۰	۷۰	۶۰	۵۰	۴۰	۳۰	۲۰	۱۰
تخمین حالت شارژ	۹۹	۹۰/۴۶	۷۹/۶۴	۶۹/۴۱	۵۹/۵۲	۵۰/۲۴	۴۱/۹۹	۲۸/۴۰	۲۰/۲۹	۰
خطای تخمین (%)	-۰/۱	۰/۵۱	۰/۴۵	۰/۸۴	-۰/۸	۰/۴۸	۴/۹	۵/۳	۱/۴۵	-۰/۵



نمودار ۱۴) منحنی V-SOC جریان تخلیه 0.35A و مقایسه داده تجربی و تخمین جریان تخلیه 0.7A




نمودار ۱۵) مقادیر خطای شبکه انفیس برای ۳ نرخ تخلیه ۰/۵، ۰/۶ و ۰/۷ آمپر در حالت‌های مختلف شارژ




نمودار ۱۶) مقادیر خطای شبکه انفیس در کل داده‌های تست

به‌منظور مقایسه عملکرد تخمین‌گرهای شبکه عصبی، انفیس و داده‌های تجربی تست که می‌توان این داده‌ها را از مدل شبیه‌سازی در MATLAB یا تست واقعی باتری استخراج نمود، به هر دو شبکه تخمین عصبی و انفیس داده شد و نتایج در نمودار ۱۲ برای نرخ تخلیه ۰/۶ آمپر ارایه شده است و در نمودار ۱۳ جریان بر حسب ولتاژ در SOC مختلف محاسبه شد.

در صورتی که در طراحی شبکه انفیس ورودی حالت شارژ باتری یا ظرفیت فعلی سلول بر حسب آمپر ساعت و نرخ جریان تخلیه در نظر گرفته شود و ولتاژ ترمینال تخمین زده شود، منحنی به‌صورت نمودار ۱۴ به دست خواهد آمد که در این نمودار، ولتاژ باتری بر حسب جریان دشارژ در حالت‌های مختلف شارژ محاسبه شده است. منحنی نمودار ۱۵ خطای شبکه انفیس را به سه نرخ مختلف در حالت شارژ مختلف ارایه می‌دهد. همان طور که در نمودار مشاهده می‌شود، مقادیر خطای شبکه کمتر از ۲٪ است.



نمودار ۱۷) مقایسه تخمین انفیس و شبکه عصبی و داده تجربی آزمون با نرخ تخلیه ۰/۶



نمودار ۱۸) تخمین ولتاژ ترمینال بر حسب جریان با استفاده از انفیس در حالت شارژ مختلف

۴- نتایج و بحث

با توجه به اهمیت مساله تخمین سیستم‌های غیرخطی مانند رابطه ولتاژ مدار باز و حالت شارژ باتری خودروهایی برقی، در این پژوهش دو روش دقت تخمین حالت شارژ شبکه عصبی Feed Forward و انفیس با یکدیگر مقایسه شدند. مقایسه منحنی نمودار ۷ و ۱۶ نشان داد که نتایج خطای شبکه انفیس نسبت به شبکه عصبی کمتر است و چون مدل انفیس از دو الگوریتم پس‌انتشار خطا و روش ترکیب گرادیان نزولی و روش حداقل مربعات خطا برای آموزش شبکه استفاده می‌کند، می‌تواند پیچیدگی الگوریتم را کاهش دهد و همزمان یادگیری شبکه را بهبود بخشد. همچنین می‌تواند به‌عنوان تخمین‌گر رابطه حالت شارژ و ولتاژ مدار باز دقیق‌تر مورد استفاده قرار گیرد. در نمودار ۱۱ دو منحنی ۰/۸ و ۰/۱ با داده‌های واقعی تست و شبکه مقایسه شده است. همان طور که در نمودار مشخص شده است، تخمین شبکه انفیس در مقایسه با شبکه عصبی بهبود تخمین را نشان می‌دهد و

منابع

- 1- IEA. Energy Technology Perspectives--scenarios and strategies to 2050. International Energy Agency. 2006;25-33.
- 2- Hannan MA, Azidin FA, Mohamed A. Hybrid electric vehicles and their challenges: A review. Renewable and Sustainable Energy Reviews. 2014;29:135-150.
- 3- Wang Y, Chen Z, Zhang C. On-line remaining energy prediction: A case study in embedded battery management system. Applied Energy. 2017;194:688-695.
- 4- Cheng KWE, Divakar BP, Wu H, Ding K, Ho HF. Battery-Management System (BMS) and SOC development for electrical vehicles. IEEE Transactions on Vehicular Technology. 2011;60(1):76-88.
- 5- Li J, Tan F, Zhang C, Sun F. Capacity fade diagnosis of Lithium ion battery pack in electric vehicle base on fuzzy neural network. Energy Procedia. 2014;61:2066-2070.
- 6- Gua Y, Zhao Z, Huang L. SoC estimation of Lithium battery based on improved BP neural network. Energy Procedia. 2017;105:4153-4158.
- 7- Chaoui H, Ibe-Ekeocha CC. State of charge and state of health estimation for lithium batteries using recurrent neural networks. IEEE Transactions on Vehicular Technology. 2017;66(10):8773-8783.
- 8- Ismail M, Dlyma R, Elrakaybi A, Ahmed R, Habibi S. Battery state of charge estimation using an Artificial Neural Network. 2017 IEEE Transportation Electrification Conference and Expo (ITEC). Piscataway: IEEE; 2017.
- 9- Liu F, Liu T, Fu Y. An improved SoC estimation algorithm based on artificial neural network. 2015 8th International Symposium on Computational Intelligence and Design (ISCID). Piscataway: IEEE; 2015.
- 10- Sarvi M, Safari M. Fuzzy, ANFIS and ICA trained neural network modeling of Ni-Cd batteries using experimental data. World Applied Programming. 2013;3(3):93-100.
- 11- Jiani D, Zhitao L, Youyi W, Changyun W. A fuzzy logic-based model for Li-ion battery with SOC and temperature effect. 11th IEEE International Conference on Control & Automation (ICCA). Piscataway: IEEE; 2014.
- 12- Shahriari M, Farrokhi M. State-of-charge estimation of VRLA batteries using neural networks and extended kalman filter. IFAC Proceedings Volumes. 2010;43(22):52-56.
- 13- Tong S, Lacap JH, Park JW. Battery state of charge estimation using a load-classifying neural network. Journal of Energy Storage. 2016;7:236-243.
- 14- Hussein AA. Capacity fade estimation in electric vehicle Li-ion batteries using artificial neural networks. IEEE Transactions on Industry Applications. 2015;51(3):2321-2330.
- 15- Li IH, Wang WY, Su SF, Lee YS. A merged fuzzy neural network and its applications in battery state-of-charge estimation. IEEE Transactions on Energy Conversion. 2007;22(3):697-708.
- 16- Gholizade-Narm H, Charkhgard M. Lithium-ion battery state of charge estimation based on square-root unscented Kalman filter. IET Power Electronics. 2013;6(9):1833-1841.
- 17- Charkhgard M, Farroukhi M. State-of-charge estimation for Lithium-ion batteries using neural networks and EKF. IEEE Transactions on Industrial Electronics. 2010;57(12):4178-4187.

همپوشانی بهتری دارد [24]. همچنین منحنی نرخ تخلیه باتری با جریان ۰/۴۵ آمپر برای اعتبارسنجی عملکرد تخمین‌گر شبکه انفیس انجام و مقادیر حالت شارژ، ولتاژ و منحنی ارایه شد. در نمودار ۶ برای ارزیابی دقیق‌تر شبکه با استفاده از رگرسیون، شبکه عصبی با قراردادن داده‌های تجربی روی داده‌های تخمین‌زده شده برای آموزش، اعتبارسنجی و مجموعه داده‌های تست با مقدار ۰/۹۹۷۱۷، مقدار نسبتاً مناسبی را نشان داد، که این مقدار نزدیک‌ترین عدد به رگرسیون ۱ با انتخاب تعداد نورون و لایه انتخاب شده است. این همبستگی نشان‌دهنده مطابقت نسبتاً خوب در برخی SOCهای پیش‌بینی‌شده و داده‌های تجربی است. نمودار ۸ مقایسه و اعتبارسنجی شبکه عصبی را در تخمین حالت شارژ باتری با نرخ تخلیه جریان ۰/۶ آمپر ارایه داده که مقدار خطا در $SOC = 10\%$ زیاد است. برای آزمون عملکرد انفیس، نمودار منحنی ۱۱ نرخ جریان تخلیه ۰/۸، ۰/۴۵ و ۰/۴۵ را ارایه نموده است. همان طور که از نمودار مشاهده می‌شود، اکثر نقاط خروجی‌های انفیس و داده‌های تجربی دارای همبستگی است یا انحراف جزئی را با خطای بسیار کمتر نسبت به شبکه FF نشان می‌دهند و به دلیل این که نرخ جریان کمتر، بیشترین خطا را نشان داد، برای بررسی و تست شبکه انفیس انتخاب شد. نمودار ۱۲ نشان داد که شبکه نوروفازی سازگار، همبستگی دقیق‌تری از حالت شارژ و ولتاژ ترمینال را نسبت به شبکه عصبی ارایه داده است و روی هم‌افتادگی منحنی تخلیه و داده‌ها در تخمین انفیس نتیجه بهتری دارد [25]. در نمودار ۱۴، منحنی ولتاژ بر حسب ظرفیت باتری ارایه شد که برای جریان 0.7A مقایسه انجام شده است. نمودار ۱۶ مقدار خطای شبکه انفیس را در کل داده‌های تست با مقدار MSE پایین‌تر ۰/۰۰۲۹ و نمودار ۱۵ خطای تخمین را با خطای قابل قبول کمتر از ۲٪ نشان داده است که مقدار مناسب را با توجه به تعداد کم داده‌های تست ارایه می‌دهد.

تشکر و قدردانی: نگارندگان بر خود لازم می‌دانند از حمایت دانشگاه تربیت دبیر شهید رجایی در انجام این تحقیق کمال تشکر و قدردانی را نمایند.

تأییدیه اخلاقی: این مقاله تاکنون در نشریه دیگری (به طور کامل یا بخشی از آن) به چاپ نرسیده است. ضمناً محتویات علمی وادبی مقاله منتج از فعالیت علمی خود نویسندگان بوده و صحت و اعتبار نتایج و متن مقاله برعهده نویسندگان مقاله است.

تعارض منافع: مقاله حاضر هیچگونه تعارض منافعی با پایان نامه/رساله و طرح پژوهشی ندارد.

سهم نویسندگان: مهرداد نوری‌خاجوی (نویسنده اول)، پژوهشگر اصلی/تحلیلگر آماری/نگارنده بحث (۶۰٪)؛ غلامرضا بیات (نویسنده دوم)، نگارنده مقدمه/روش‌شناس/پژوهشگر کمکی (۴۰٪)

منابع مالی: این تحقیق با حمایت مالی دانشگاه تربیت دبیر شهید رجایی به انجام رسیده است.

۵- پی‌نوشت

علامت	
C_n	ظرفیت اسمی باتری (بر حسب آمپر ساعت)
$I(t)$	جریان شارژ یا تخلیه
x_i	آمین داده ورودی شبکه برای نرمال‌سازی
x_{min}	کمترین مقدار داده ورودی
x_{max}	بیشترین مقدار داده ورودی
$\mu_{A_i}(x)$	مقدار عضویت هر یک از ورودی‌های شبکه
w_i	خروجی آمین گره شبکه انفیس

Society for Industrial and Applied Mathematics. 1963;11(2):431-441.

22- Xing Y, Ma EWM, Tsui KL, Pecht M. Battery management systems in electric and hybrid vehicles. *Energies*. 2011;4(11):1840-1857.

23- Nori Khajavi M, Bavir MR, Farrokhi E. A new method in determining rotor crack depth by using multi-scale permutation Entropy and ANFIS network. *Modares Mechanical Engineering*. 2015;15(7):31-39. [Persian]

24- Awadallah MA, Venkatesh B. Accuracy improvement of SOC estimation in lithium-ion batteries. *Journal of Energy Storage*. 2016;6:95-104.

25- Wu T, Wang M, Xiao Q, Wang X. The SOC estimation of power Li-Ion battery based on ANFIS model. *Smart Grid and Renewable Energy*. 2012;3:51-55.

18- He Z, Chen D, Pan C, Chen L, Wang S. State of charge estimation of power Li-ion batteries using a hybrid estimation algorithm based on UKF. *Electrochimica Acta*. 2016;211:101-109.

19- Anand I, Mathur BL. State of charge estimation of lead acid batteries using neural network. 2013 International Conference on Circuits, Power and Computing Technologies (ICCPCT). Piscataway: IEEE; 2013.

20- Chen M, Rincon-Mora GA. Accurate electrical battery model capable of predicting runtime and I-V performance. *IEEE Transactions on Energy Conversion*. 2006;21(2):504-511.

21- Marquardt DW. An algorithm for least-squares estimation of nonlinear parameters. *Journal of the*