

基于栈式自编码深度学习的电池健康状态估计

李春晖, 蔡 威, 喻小花, 黄康君, 廖 崇

广东电网有限责任公司广州供电局, 广东 广州

收稿日期: 2025年5月19日; 录用日期: 2025年6月12日; 发布日期: 2025年6月20日

摘 要

随着新能源和储能技术的快速发展, 智能电池能量管理系统(BEMS)在电力系统中的应用变得日益重要。然而, 现有的电池管理方法大多基于固定规则, 缺乏在复杂和动态环境中的灵活响应能力, 这限制了电池状态估计和剩余寿命预测的准确性。本文提出了一种基于栈式自编码器(SAE)和通道注意力机制(SENNet)的电池健康状态估计方法。通过分析电池的充放电数据, 提取关键健康因子, 并利用SAE深度学习模型进行特征融合。结合SENNet模块自适应调整特征的权重, 从而提升模型的预测能力和精度。与传统的基于主成分分析(PCA)和非线性神经网络的方法相比, 该方法在提取电池退化特征方面更加高效, 并在容量估计和剩余寿命预测中实现了更高的精度和稳定性。此外, 该方法具有良好的实时性和鲁棒性, 能够有效应对复杂环境的变化。

关键词

电池健康状态估计, 栈式自编码器, 注意力机制, 剩余寿命预测, 电池退化特征提取

Battery Health State Estimation Based on Stacked Autoencoder Deep Learning

Chunhui Li, Wei Cai, Xiaohua Yu, Kangjun Huang, Chong Liao

Guangdong Power Grid Co., Ltd. Guangzhou Power Supply Bureau, Guangzhou Guangdong

Received: May 19th, 2025; accepted: Jun. 12th, 2025; published: Jun. 20th, 2025

Abstract

With the rapid development of renewable energy and energy storage technologies, smart Battery

文章引用: 李春晖, 蔡威, 喻小花, 黄康君, 廖崇. 基于栈式自编码深度学习的电池健康状态估计[J]. 智能电网, 2025, 15(3): 57-63. DOI: 10.12677/sg.2025.153006

Energy Management Systems (BEMS) have become increasingly critical in power systems. However, most existing battery management methods rely on fixed rules, lacking flexible responsiveness in complex and dynamic environments, which limits the accuracy of battery state estimation and remaining useful life prediction. This paper proposes a State of Health (SOH) estimation method for batteries based on a Stacked Autoencoder (SAE) and a channel attention mechanism (SENet). By analyzing battery charge/discharge data, key health indicators are extracted, and a SAE-based deep learning model is employed for feature fusion. Combined with the SENet module, the proposed method adaptively adjusts feature weights to enhance prediction capability and accuracy. Compared with traditional approaches such as Principal Component Analysis (PCA) and nonlinear neural networks, this method demonstrates higher efficiency in extracting battery degradation features and achieves superior precision and stability in capacity estimation and remaining useful life prediction. Additionally, the proposed framework exhibits excellent real-time performance and robustness, enabling effective adaptation to environmental variations in complex scenarios.

Keywords

Battery Health State Estimation, Stacked Autoencoder, Attention Mechanism, Remaining Useful Life, Battery Degradation Feature Extraction

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着全球对可再生能源的需求日益增加, 电池作为能源存储和管理的关键组件, 正广泛应用于电力系统、智能电网、电动汽车及其他储能设备中[1]。智能电池能量管理系统(BEMS)是确保电池性能、延长使用寿命和提高系统稳定性的核心技术之一。然而, 现有的电池管理方法通常依赖于基于规则的方法, 主要通过固定参数和预设逻辑进行能量分配和控制[2]。这类方法在处理电池状态变化复杂的情况下, 往往表现出较差的灵活性和准确性, 尤其在面对多变的工作环境和电池退化状态时, 无法提供实时、精准的预测结果。

电池健康状态(State of Health, SOH)估计和剩余寿命(Remaining Useful Life, RUL)预测是电池管理中至关重要的环节[3]。准确的 SOH 估计可以有效评估电池的实际健康状态, 帮助优化能量管理策略, 而 RUL 预测则有助于提前识别电池的故障风险, 从而延长电池使用寿命并避免系统故障。尽管已有多种基于模型的方法尝试解决这些问题, 但大多数方法依赖于复杂的物理模型和大量的实验数据, 难以在实际应用中实现实时性和高精度。而且, 传统的特征提取方法, 如主成分分析(PCA)等, 往往难以处理电池退化过程中的非线性和高维数据。

为了解决这些问题, 近年来, 深度学习技术被逐渐应用于电池健康状态估计与寿命预测领域[4]。例如, 支持向量回归(SVR) [5]、K 最近邻(KNN) [6]和随机森林(RF) [7]等传统机器学习方法。随着深度学习的发展, 基于卷积神经网络(CNN) [8]、长短时记忆网络(LSTM) [9]、循环神经网络(RNN) [10]等深度学习模型的研究逐渐增多, 并取得了显著的进展。自编码器(Autoencoder, AE)模型在无监督学习中展示了强大的特征提取能力, 能够从大量的电池数据中学习到的潜在的特征, 并通过深度神经网络进行更加精准的状态估计[11]。然而, 单一的自编码器模型在处理复杂的电池退化特征时, 仍然面临着提取效率和准确度的瓶颈。为此, 本文提出了一种基于栈式自编码器(SAE)和通道注意力机制(SENet)的电池健康状态估计方

法。通过栈式自编码器对电池充放电数据进行深度特征融合，并结合通道注意力机制自适应地调整不同特征的权重，从而提升电池健康状态估计的准确性与鲁棒性。与传统基于 PCA 和非线性神经网络的预测方法相比，本文方法能够更有效地提取电池退化特征，在容量估计和剩余寿命预测方面实现更高的精度和稳定性。

2. 栈式自编码深度学习

本节首先介绍自编码器(AE)的基本原理，然后通过扩展其为栈式自编码器(SAE)，进一步提升了模型的特征提取和健康状态估计能力。

2.1. 自编码器

自编码器是一种无监督学习的神经网络，主要由编码器和解码器两部分组成，用于将输入数据映射到低维空间并进行重建。自编码器的目标是学习到一种有效的表示，能够将输入数据压缩成更小的隐藏层表示，同时尽可能准确地重建原始数据。自编码器通常用于降维、特征提取和数据预处理。

设输入数据为 $x \in R^n$ ，自编码器首先通过编码器映射到低维表示 $h \in R^m$ ：

$$h = f(x) = \sigma(W_1 x + b_1) \quad (1)$$

式中， $W_1 \in R^n$ 是编码器的权重矩阵， b_1 是偏置， σ 是 sigmoid 激活函数。然后，解码器将该低维表示 h 映射回原始空间，重建输出 x' ：

$$x' = g(h) = \sigma(W_2 h + b_2) \quad (2)$$

式中， W_2 也是编码器的权重矩阵， b_2 是偏置， $g(x)$ 是解码器的激活函数。自编码器通过最小化重建误差来训练网络，常用的损失函数为均方误差：

$$L(x, x') = \frac{1}{n} \sum_{i=1}^n (x_i - x'_i)^2 \quad (3)$$

自编码器的目标是将输入数据 x 压缩到隐层表示 h ，并通过最小化损失函数来尽量重建输入数据。这样，网络通过无监督的方式学习到了输入数据中的主要特征。

2.2. 栈式自编码深度学习

栈式自编码器深度学习 SAE 是由多个自编码器层堆叠而成的一种深度神经网络结构，每一层自编码器都学习到输入数据的不同特征，从而提升了特征表示的抽象能力。栈式自编码器是无监督学习的典型方法，能够逐层学习复杂的特征，并且通过多层非线性变换对输入数据进行有效的特征提取。

在栈式自编码深度学习中，每个自编码器的隐层输出作为下一个自编码器的输入，从而通过逐层训练的方式提取数据的高层次特征。给定输入数据 $X = [x^1, x^2, \dots, x^T]$ ，(其中 T 为数据的时间步数)，首先使用第一个自编码器将输入映射到隐层表示 h_1 ，

$$h_1 = f_1(X) = \sigma(W_1 X + b_1) \quad (4)$$

然后，第二个自编码器将第一个隐层输出作为输入，进一步映射到第二个隐层表示 h_2 ，以此类推，最终得到第 L 层的隐层表示 h_L ：

$$h_L = f_L(h_{L-1}) = \sigma(W_L h_{L-1} + b_L) \quad (5)$$

每一层的训练都是在上一层训练完成之后进行的，通过逐层预训练和微调，可以提高模型的鲁棒性和泛化能力。SAE 的输出通常用于进行回归或分类任务，如图 1 所示。




Figure 1. Stacked autoencoder architecture
图 1. 栈式自编码结构图

3. 电池健康状态估计

本文提出了一种基于栈式自编码器和通道注意力机制相结合的电池健康状态估计方法，通过特征提取与融合，在复杂工况下实现电池健康状态的高效预测。

3.1. 通道注意力机制

SENet 是一种自适应的特征重标定方法，旨在通过显式建模通道之间的依赖关系，增强网络对于重要特征的表达能力。SENet 通过学习每个通道的注意力系数，对每个通道的特征进行加权，增强网络对重要通道特征的关注，从而提升模型在任务中的表现。

SENet 的核心思想是通过两个步骤：压缩和激励来为每个通道分配一个权重，从而强化重要通道的信息，抑制不重要的通道信息。压缩通过全局平均池化操作对每个通道进行信息压缩，得到每个通道的全局上下文信息，表示该通道的全局特征。激励通过一个全连接层计算每个通道的激励系数，使用 Sigmoid 激活函数将其映射到一个介于 0 和 1 之间的权重，用于加权每个通道的特征。

设输入特征图为 $X \in R^{C \times H \times W}$ ，其中 C 是通道数， H 和 W 分别是特征图的高度和宽度。首先，对输入特征图的每个通道进行全局平均池化，计算每个通道的全局信息：

$$Z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_{cij}, c = 1, 2, \dots, C \quad (6)$$

其中， x_{cij} 是输入特征图中第 c 个通道在位置 (i, j) 的特征值， z_c 是第 c 个通道的全局信息，表示该通道的特征图上所有空间位置的平均值。通过全局平均池化操作，输入的 $C \times H \times W$ 的特征图被压缩成了一个 C 维的向量 $z = [z_1, z_2, \dots, z_c]$ 。

然后，通过激励操作生成每个通道的注意力系数。首先，对压缩后的向量 z 通过一个全连接层进行变换。该全连接层由两个线性变换组成，其中第一个全连接层将输入的 C 维向量压缩到一个较小的维度 C/r (r 是缩放因子，通常取值在 2 到 16 之间)，第二个全连接层再将其还原为原始的 C 维输出，数学描述如下：

$$s = \sigma(W_2 \delta(W_1 z + b_1) + b_2) \quad (7)$$

式中 s 为输出。

最后，利用得到的通道注意力系数 s ，对输入的特征图进行加权，生成重标定后的特征图。具体操作为：

$$X' = X \odot s \quad (8)$$

其中, $\odot$ 表示逐元素相乘操作, X' 是加权后的特征图。通过这种加权操作, 网络可以在训练过程中自适应地学习每个通道的权重, 从而更加关注对任务重要的通道特征, 抑制不重要的特征。

SENet 通过学习每个通道的注意力系数, 使得网络能够自动调整特征图中不同通道的重要性。这种自适应的加权机制能够更好地提升模型对重要特征的表达能力。

3.2. 基于 SAE 和 SENet 的电池健康状态估计

本节提出了一种基于栈式自编码器和通道注意力机制结合的电池健康状态估计方法。该方法能够在复杂的电池工作环境下, 通过自动学习电池特征并加权提升预测精度, 从而实现对电池健康状态的高效估计。首先, 电池的工作数据(如电压、电流、温度等)经过多层 SAE 模型, 提取电池的隐含特征。然后, SENet 根据这些特征为每个通道分配一个注意力权重, 以便增强与电池健康状态相关的特征, 同时抑制不重要的信息。该方法的核心在于将 SAE 的深度特征学习与 SENet 的通道加权机制结合, 从而有效提高电池 SOC 预测的准确性与鲁棒性。

在电池健康状态估计任务中, 我们的输入数据主要包括电池的电压、电流、温度和 SOC 等历史数据。为了使得输入数据能够适应 SAE 模型的训练, 我们对这些数据进行了预处理。首先, 对每个电池工作状态的数据进行归一化处理, 以消除不同量纲之间的影响:

$$x'_i = \frac{x_i - \mu}{\varphi} \quad (9)$$

其中, x_i 是原始数据, μ 和 φ 分别是数据的均值和标准差, x' 是归一化后的数据。然后, 对这些数据进行数据清洗、异常值剔除等预处理。

3.3. 公式

本文所提出的电池健康状态估计的算法包括数据预处理、SAE 特征学习、SENet 特征加权、电池健康状态预测、模型评估与优化和结果输出。

(1) 数据预处理。收集电池的实时工作数据(如电压、电流、温度等)。对数据进行归一化处理, 确保特征在相同的尺度范围。并进行数据清洗、异常值处理等操作。将数据集划分为训练集、验证集和测试集。

(2) SAE 特征学习。构建栈式自编码器(SAE), 包含多个编码器和解码器层。输入数据通过编码器压缩为低维度特征表示。使用均方误差(MSE)最小化重构误差, 进行训练并提取电池健康状态的深层特征。

(3) SENet 特征加权。对 SAE 输出的特征图进行全局平均池化。计算每个通道的重要性权重, 并通过激励函数进行自适应调整。将加权后的特征向量输入至下游任务。

(4) 电池健康状态预测。利用加权后的特征进行 SOC 预测并剩余使用寿命估计。通过回归模型实现电池健康状态的量化。

(5) 模型评估与优化。评估模型的预测精度和鲁棒性, 使用均方误差(MSE)、平均绝对误差(MAE)等指标进行评估。基于测试结果进行参数调整, 优化模型的预测性能。

(6) 结果输出。输出电池 SOC、剩余寿命等健康状态指标, 供电池管理系统(BEMS)实时监控和决策。

4. 算例分析

4.1. 实验设置

为了验证所提出的基于 SAE 和 SENet 的电池健康状态估计方法的有效性, 我们采用均方误差 MSE、

均方根误差 RMSE、平均绝对误差 MAE 和相关系数 R 四个指标。实验中，我们将数据集分为训练集和测试集，其中 70%的数据用于训练和验证，30%的数据用于测试。为了确保实验的公平性，所用数据为公开数据集[12]，含实际电池充放电数据，包括电池电压、电流、温度和 SOC 等多维特征。对比方法包括支持向量机 SVM、人工神经网络 ANN 和自回归积分滑动平均 ARIMA。

4.2. 实验结果

表 1 展示了本文所提出的方法与其他传统算法在电池 SOC 预测中的性能比较。具体来看，在 MSE 指标中，本文提出的方法表现最佳，较其他传统方法(如支持向量机 SVM、人工神经网络 ANN 和 ARIMA)均低 15%以上。这表明，本文所提出模型在预测电池 SOC 时能够较为准确地拟合实际数据，误差较小，从而提高了 SOC 预测的精准度。

在均方根误差方面，本文所提出的方法同样展现出优越性能。RMSE 值较低说明预测结果较为稳定，模型输出的波动性较小，具有较好的稳定性，这对于电池管理系统的实时性和可靠性非常重要。在 MAE 评估中，本文所提出的方法也明显优于 SVM、ANN 和 ARIMA。MAE 能够衡量模型预测值与真实值之间的平均偏差，低 MAE 值意味着模型的预测结果误差较小，且能够有效地减少对极端错误预测的敏感性。同样，本文所提出方法的相关系数明显高于其他方法，表明 SAE 能够更好地捕捉电池 SOC 的变化趋势，从而提升了预测的可靠性和准确性。

Table 1. Experimental comparison results

表 1. 实验对比结果

模型	MSE	RMSE	MAE	R
本文所提出方法	0.012	0.109	0.085	0.95
SVM	0.015	0.124	0.091	0.92
ANN	0.014	0.119	0.089	0.93
ARIMA	0.016	0.016	0.092	0.89

4.3. 实验分析

根据实验结果，可以看出，本文所提出的方法在所有评估指标上均显著优于其他传统方法，展现出明显的优势，具体体现在精准度与稳定性、非线性建模能力、时序特征捕捉能力和泛化能力等方面。首先，所提出模型的 MSE 和均方根误差 RMSE 值最低，表明该方法能够准确地预测电池 SOC，并且预测结果的波动性较低，稳定性较好。其次，相比 SVM 和 ANN，所提出方法在处理电池 SOC 预测中的复杂非线性关系方面具有明显优势，尤其在电池退化和充放电过程中的非线性变化表现尤为突出。再次，电池 SOC 的变化不仅受到电池内部化学反应的影响，还受多种外部因素的作用，SAE 通过多层自编码器的结构，能够更好地捕捉电池工作状态随时间变化的时序特征，并适应电池状态的动态变化。

最后，SAE 模型在训练集和测试集上的表现均较为稳定，且相关系数较高，表明其具备较强的泛化能力，能够在不同工况下进行有效预测，从而为电池能量管理系统提供更精确的支持。

5. 结论

本文提出了一种基于栈式自编码器和通道注意力机制相结合的电池健康状态估计方法，从而提高电池 SOC 预测的精度与稳定性。通过使用 SAE 模型提取电池充放电数据中的深层特征，并结合 SENet 模块对特征加权调整，本文方法能有效处理电池在复杂工况下的非线性变化和时序特性。实验结果表明，

所提方法在 MSE、RMSE、MAE 和相关系数等评估指标上均优于传统方法,如支持向量机(SVM)、人工神经网络(ANN)和 ARIMA 模型,表现出较低的预测误差和较高的精度。此外,本文方法在训练集和测试集上均具有较好的泛化能力,能够适应不同工况下的电池状态变化,具备较强的实时性和鲁棒性。总体来看,本文提出的方法为电池管理系统提供了更精准、稳定的 SOC 预测,并具有良好的实际应用前景。

参考文献

- [1] 刘俊,高也,齐宇蓉,等.基于马尔科夫链的可再生能源电力超额消纳量预测研究[J].自动化技术与应用,2025,44(4):164-168.
- [2] 王辰,汤奕,郑晨一.基于动态优化周期的风光氢储耦合系统改进能量管理策略[J].电力系统自动化,2025,49(2):142-153.
- [3] 王欣,郑赟,秦斌.考虑电池 SOC 一致性的城轨交通 MHESS 功率分配策略[J].现代电子技术,2024,47(22):99-106.
- [4] 勇兰.用于预测电池寿命的新型深度学习模型[J].科学,2024,76(5):38.
- [5] 张迪俊.基于 PSO-RBFNN 的电动汽车锂电池 SOC 预测[J].汽车维修,2024(1):10-14.
- [6] 于秋月,刘江岩,何林,等.基于机器学习的锂离子电池荷电状态多步预测[J].汽车工程学报,2023,13(4):586-596.
- [7] 寇发荣,罗希,门浩,等.基于特征优选与改进极限学习机的锂电池 SOC 估计[J].储能科学与技术,2023,12(4):1234-1243.
- [8] 池贝贝.基于 DEKF 联合 CNN-LSTM-Attention 的锂电池 SOC 估计[J].软件,2024,45(7):134-137.
- [9] 刘阳阳.基于优化 LSTM 新能源汽车 SOC 估算的研究[J].汽车维修技师,2024(20):31-32.
- [10] 范元亮,吴涵,黄兴华,等.基于松弛特性和主成分分析的锂离子电池荷电状态估计[J].电气工程学报,2024,19(4):337-346.
- [11] 黄旭,许冬云.基于 MF-SAE-SSA-KELM 油浸式变压器故障诊断方法[J].工业控制计算机,2024,37(10):126-128.
- [12] https://github.com/standing-o/SoH_estimation_of_Lithium-ion_battery