

基于 GA-ANFIS 的装甲车辆 蓄电池 SOH 预测方法

朱永黎^{1,2}, 常天庆¹, 刘鹏³

(1. 陆军装甲兵学院, 北京 100000; 2. 中国人民解放军 68207 部队, 甘肃 嘉峪关 735100;
3. 陆军特种作战学院, 广西 桂林 541000)

摘要: 为保持装甲车辆的机动安全和运行可靠, 提高其铅酸蓄电池健康状态的预测能力至关重要; 将遗传算法与自适应模糊神经网络相结合, 提出了一种基于 GA-ANFIS 的装甲车辆蓄电池 SOH 预测方法, 着重分析了该方法的总体流程和训练过程; 着眼装甲车辆的工作环境, 在放电深度和输出能量的基础上, 引入海拔和温度作为模型的输入; 在 Matlab 的实验结果表明, GA-ANFIS 相比 ANFIS 测试数据误差减小 47.6%, 四输入 GA-ANFIS 相比两输入 GA-ANFIS 测试数据误差减小 51.2%, 验证了方法的有效性。

关键词: 健康状态; 铅酸蓄电池; 遗传算法; 自适应模糊神经网络

SOH Prediction Method of Armored Vehicle Batteries Based on GA-ANFIS

Zhu Yongli^{1,2}, Chang Tianqing¹, Liu Peng³

(1. Army Academy of Armored Forces, Beijing 100000, China; 2. PLA Unit 68207, Jiayuguan 735100, China;
3. Army Academy of Special Operations, Guilin 541000, China)

Abstract: In order to keep the armored vehicles safe and reliable, it is very important to improve the ability of predicting the state of health of lead-acid batteries. A method of SOH prediction for armored vehicle batteries based on GA-ANFIS is proposed, which combines genetic algorithm with adaptive network-based fuzzy inference system. The overall process and training process of the method are emphatically analyzed. Aiming at the working environment of armored vehicles, elevation and temperature are introduced as the input of the model on the basis of discharge depth and output energy. The experimental results in Matlab show that the error of GA-ANFIS is 47.6% less than that of ANFIS, and that of four-input GA-ANFIS is 51.2% less than that of two-input GA-ANFIS.

Keywords: state of health; lead-acid battery; genetic algorithm; adaptive network-based fuzzy inference system

0 引言

在装甲车辆操作使用和维护的过程中, 蓄电池的能量供应关系到装甲车辆的机动安全和运行可靠。为了保证装甲车辆的电池性能良好, 延长电池寿命, 必须对蓄电池的健康状态(State of Health, SOH)进行及时、准确的监测。通过 SOH 预测可识别电池性能的降低并检测其生命周期的终止。SOH 反映的是电池使用一段时间后, 性能参数与标称参数的比值。未使用过的新电池, 在生命周期开始时, SOH 的值是 100%, 随着使用时间而减少, 直到生命周期结束。在 SOH 小于一定比例时, 蓄电池不能继续使用, 需要进行维修或替换^[1], 因此, 准确的 SOH 预测可避免对军用蓄电池做过多的维护和检修, 降低了其使用成本并及时避免装甲车辆训练中意外故障的发生。

SOH 是不可直接测量的理论上的概念, 相比荷电状态

(State of Charge, SOC) 的预测更加复杂, 需要从与电池健康相关的其他因素推断出来。电池电量的退化程度依赖使用情况、操作模式和工作环境^[2-3], SOH 预测精度不仅取决于电池模型的可靠性, 而且取决于模型中参数选取的准确性。同时, 军用蓄电池与民用蓄电池在业务需求、使用场景等方面均存在一定差异。因此, 对装甲车辆军用蓄电池进行 SOH 预测, 是一项具有一定挑战的研究课题。本文从两方面入手对装甲车辆蓄电池 SOH 展开预测, 一方面将遗传算法与自适应模糊神经网络相结合, 改进预测模型; 另一方面, 在传统输入参数放电深度和输出能量的基础上, 引入海拔和温度, 改进模型输入, 实验结果有效验证了所提方法的有效性。

1 相关研究

SOH 预测的基本方法是基于对充放电过程中存储和消耗的能量进行计数。这种方法称为库仑计数, 可以在两种不同的方式进行预测。一种为恒定负载测试期间的库仑计数, 需要一个核对性放电过程, 依据终止电压结束放电,

收稿日期:2018-12-19; 修回日期:2019-01-25。

作者简介:朱永黎(1973-),男,新疆哈密人,硕士研究生,主要从事自动测试系统方向的研究。

按一定时间间隔采集数据, 并计算 SOH。另一种为日常使用期间可变负载的库伦计数, 尽管这种方法更贴近于实际, 但会引入累计测量误差^[4]。同时, 不同的使用环境也需要对算法进行改进, 并采取连续校准来减小所引入的误差^[5]。

在库伦计数的基础上, SOH 相关的物理参数的识别和建模方面存在大量研究, 如开路电流电压^[6]、电阻^[7]、温度^[8]、端电压^[9]、电压和电流曲线^[10]等。在这些方法中, 通过构建模型由物理参数计算电池 SOH 的数值。等效电路模型是建模电池内阻和电池充放电过程中行为两者关系的典型例子^[11]。欧阳等人使用化学动力学来建模电池退化的过程^[12], 通过该模型测量特定参数来预测不可测参数的值。同时, 部分研究集中在智能算法和统计方法方面, 包括人工神经网络^[13]、模糊逻辑^[14]、粒子滤波器^[15]、支持向量机^[16]、卡尔曼滤波器^[17]、k-近邻回归和粒子群优化技术^[18]。本文在库伦计数方法、物理参数识别和建模的基础上展开优化, 将遗传算法 (GA) 与自适应模糊神经网络 (ANFIS) 相结合, 并将装甲车辆运行环境中涉及的海拔和温度两参数作为输入引入模型, 以改进算法的优化效果。

2 基于 GA-ANFIS 的 SOH 预测方法

2.1 总体流程

本文将遗传算法和自适应模糊神经推理系统两者相结合, 应用于 SOH 预测, 设计了基于 GA-ANFIS 的 SOH 预测算法, 总体流程图如图 1 所示, 主要包含 5 个阶段。

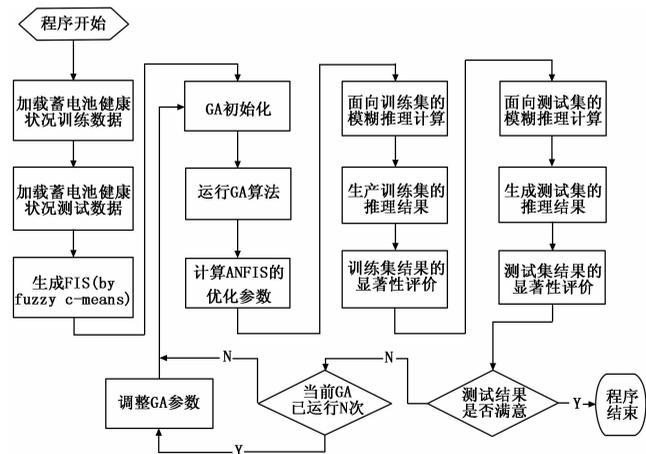


图 1 蓄电池健康状态 GA-ANFIS 预测算法

具体步骤分阶段进行如下说明:

1) 第一阶段为 FIS 初始化部分:

第一步, 加载蓄电池健康状况的训练数据, 该数据为在各种条件下采集得到的数据;

第二步, 加载蓄电池健康状况的测试数据;

第三步, 根据加载数据生成 FIS, 主要通过模糊 C 均值聚类的方法实现。跳转第二阶段。

2) 第二阶段为 GA 算法的训练部分:

第一步, GA 初始化, 包括交叉、突变比例、迭代次数、人口数等各类参数;

第二步, 根据初始化后的参数, 运行 GA 算法;

第三步, 计算生成 ANFIS 的优化参数。跳转第三阶段。

3) 第三阶段为训练集的评价部分:

第一步, 面向训练集模糊推理计算;

第二步, 生成训练集的推理结果;

第三步, 对训练集结果进行显著性评价, 主要是统计意义的检验。跳转第四阶段。

4) 第四阶段为测试集的评价部分:

第一步, 面向测试集模糊推理计算;

第二步, 生成测试集的推理结果;

第三步, 对测试集结果进行显著性评价, 主要是统计意义的检验。跳转第五阶段。

5) 第五阶段为结果的满意度评估部分:

第一步, 根据用户设置的初始值, 判断结果是否满意, 若满意则程序结束; 否则跳转第二步;

第二步, 计数判断当前 GA 已运行的次数, 若超过最大运行次数时, 跳转第三步; 否则, 跳转第二阶段第一步;

第三步, 根据用户预先设置的 GA 范围自动调整参数范围, 跳转第二阶段第一步。

2.2 训练过程

整个算法的核心是使用 GA 训练 ANFIS 的过程, 流程图见图 2。该过程处于 GA-ANFIS 框架整体流程的第二阶段。第二阶段开始后, 首先获取第一阶段计算得到的隶属度相关参数, 并将该参数序列化, 序列化后的参数为遗传算法的寻优参数。而后, 初始化遗传算法的配置参数, 这些参数包括人口数、迭代数、交叉比例、突变比例、选择压力、突变率等等, 并根据部分上述参数生成初始人口。针对初始人口, 展开 FIS 模糊推断并计算开销, 输入变量是关于训练数据的输入矩阵, 输出变量为 FIS 推测得出的电池剩余载荷。开销用两个误差统计项来表示, 即: 均方误差 MSE 和均方根误差 RMSE 来表示。

遗传算法的进化在一定迭代次数内完成, 主要算子包括选择、交叉和突变。在每一代计算中, 首先将开销做归一化处理, 计算每个人口的使用度。选择父亲节点进行进化的方法是传统的轮盘赌方法, 适应度强的节点具有较大选择概率。每次迭代通过交叉算子生成两个后代, 并对后代的开销进行评估。突变算子在交叉算子后执行, 随机选择父亲节点, 并通过突变算子操作生成后代。当交叉和突变生成的后代满足指定数目后, 连同上一代节点进行人口归并, 并做开销排序。按每一代的人口上限截取后, 更新最好开销和最坏开销的节点。当到达最大迭代数 N 或连续几代内开销的改进小于阈值 T 时, 整个迭代过程结束。记录最优的 FIS 参数并生成最优 FIS。该 FIS 将最终用于电池剩余载荷的预测。

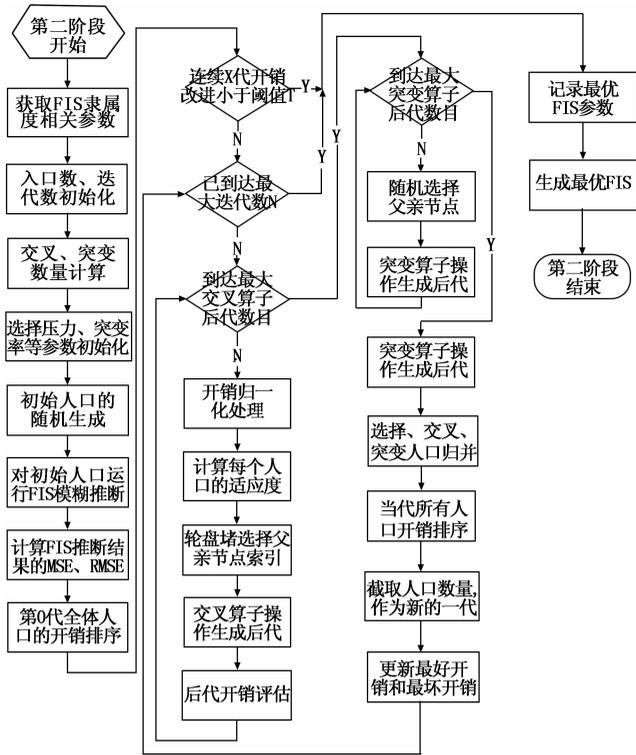


图 2 使用 GA 训练 ANFIS 的算法流程

3 实验与分析

3.1 输入变量的选择

测试对象为主流装甲车辆的一款铅酸蓄电池。蓄电池 SOH 受诸多因素影响，这些因素包括端电压、电池内阻、温度、自放电因子、老化程度、电解液密度、放电电流等。文献 [19-20] 对蓄电池 SOH 的影响因素进行了分析，认为电解液浓度、自放电因子、蓄电池内阻等因素不宜作为 SOH 预测的输入变量。相关研究^[20-23]普遍认为应选择放电深度和输出能量两者作为输入变量。

然而，我国幅员辽阔、边境线漫长，适用于装甲车辆的铅酸蓄电池的工作环境与工业等民用蓄电池的使用环境差异很大，并非常年工作于常温常压的平原地区。尤其对于高原高寒环境地域，低温低压会降低负极活性物质的利用率，导致电池内阻增大，并最终影响蓄电池的容量^[24]。因此，本文在预测装甲车辆铅酸蓄 SOH 健康状况中，考虑加入温度和海拔两个输入变量，并分析温度和海拔在改进装甲车辆铅酸蓄 SOH 预测中的效果。

3.2 实验方法

课题组在西北戈壁及祁连山脉展开实验研究和数据采集，所在地域的海拔范围 1200~5150 米，选择地域内 1305、2580、3157 和 4233 四个点位的海拔高度，数据采集的同时，记录当时的温度。实验中采用了 80 组装甲车辆的铅酸蓄电池，放电深度分别为 0.05、0.1、0.15 和 0.2。每组电池在每个点位采集输出能量、海拔、温度数据 8 组，

共产生 2560 组数据。

在运行 GA-ANFIS 算法时，将 70% 的数据 (1792 组) 作为测试数据，同时将剩余 30% 的数据 (768 组) 作为预测数据。为避免按时间先后采集数据可能造成实验结果的偏差，在划分测试数据和预测数据前，进行了数据的随机混洗。

实际容量的获取采用了核对性放电方法进行测量。输出能量按等间隔时间采集电压值和电流值，累加计算的方法进行。数据采集完成后，输出能量按最高值做归一化处理。

GA-ANFIS 算法所执行的硬件环境为华为服务器 RH2488V5，软件环境为 Matlab2016a。为了验证 GA-ANFIS 相比 ANFIS 的改进效果，首先利用 MATLAB 中模糊神经网络工具箱，进行 ANFIS 的模糊推断，以分析 GA-ANFIS 相比无 GA 寻优情况下 ANFIS 算法的预测效果。GA-ANFIS 的实验中分别对两输入和四输入的情况分别运行算法，记录均方误差 MSE、均方根误差 RMSE、误差均值和误差标准差。由于遗传算法是一种随机搜索算法，每次执行往往会得到不同且接近的结果，对每一类输入的情况，实验中运行五次 GA-ANFIS 算法，并采用均值作为算法的输出结果进行比对分析。

3.3 实验结果

本文进行了 4 组实验，分别为两输入 ANFIS (ANFIS2)、四输入 ANFIS (ANFIS4)、两输入 GA-ANFIS (GA-ANFIS2) 和四输入 GA-ANFIS (GA-ANFIS4)。

3.3.1 ANFIS2 实验结果

ANFIS2 的输入变量为放电深度和输出能量。模糊系统采用三个模糊子集覆盖每个输入量，并产生三个输出。放电深度和输出能量分别有 3 个隶属度函数，该函数的类型可选择三角形隶属函数 (trimf)、高斯形隶属函数 (gaussmf)、广义钟型隶属函数 (gbellmf)、双 S 形乘积隶属函数 (psigmf) 等 11 种。由于 GA-ANFIS 的 matlab 实现中采用了 gaussmf 隶属函数，为保证相同条件下实验结果做对比，ANFIS 实验中同样采用 gaussmf 隶属函数，不同隶属度选择下对 ANFIS 的优化效果不在本文的探讨范围内。放电深度和输出能量两输入量的初始高斯隶属函数的参数为：[0.17 0]、[0.17 0.5]、[0.17 1]。

图 3 为 ANFIS2 模型测试数据的预测结果。平均训练误差为 0.037424，平均测试误差为 0.03767。

3.3.2 ANFIS4 实验结果

ANFIS4 的输入变量为放电深度、输出能量、海拔和温度。模糊系统采用三个模糊子集覆盖每个输入量，并产生 27 个输出。放电深度、输出能量、海拔和温度四个输入量分别有 3 个隶属度函数，该函数在 ANFIS 实验中同样采用 gaussmf 隶属函数。放电深度的初始高斯隶属函数的参数为：[0.03185 0.05]、[0.03185 0.125]、[0.03185 0.2]，

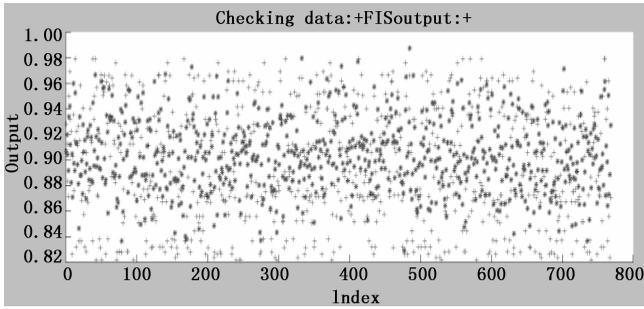


图 3 ANFIS2 模型测试数据的预测结果

输出能量的初始高斯隶属函数的参数为: $[0.1745 \ 0.1785]$ 、 $[0.1744 \ 0.5892]$ 、 $[0.1744 \ 1]$, 海拔的初始高斯隶属函数的参数为: $[0.6158 \ 1.3]$ 、 $[0.6158 \ 2.75]$ 、 $[0.6158 \ 4.208]$, 温度的初始高斯隶属函数的参数为: $[10.19 - 18]$ 、 $[10.19 \ 6]$ 、 $[10.19 \ 30]$ 。

图 4 为 ANFIS4 模型测试数据的预测结果。平均训练误差为 0.026143, 平均测试误差为 0.026469。

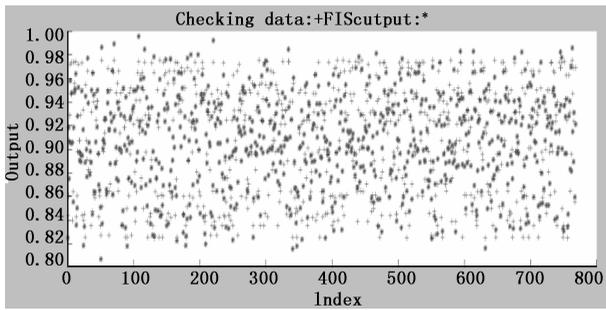


图 4 ANFIS4 模型测试数据的预测结果

3.3.3 GA-ANFIS2 实验结果

GA-ANFIS2 实验中训练数据的结果见图 5、图 6, 图中分别给出了输出结果的误差指标和输出结果的误差指标的统计特性。

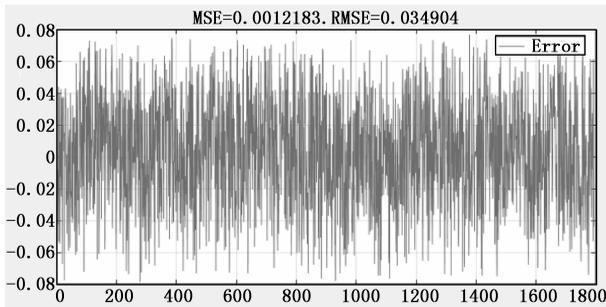


图 5 GA-ANFIS2 训练数据输出结果的误差指标

测试数据的结果见图 7、图 8, 图中分别给出了输出结果的误差指标和输出结果的误差指标的统计特性。

实验中依次记录 5 次 GA-ANFIS 算法的均方误差、均方根误差、平均误差和误差标准差, 并计算每个指标的均值, 得到表 1 和表 2 所示的结果。

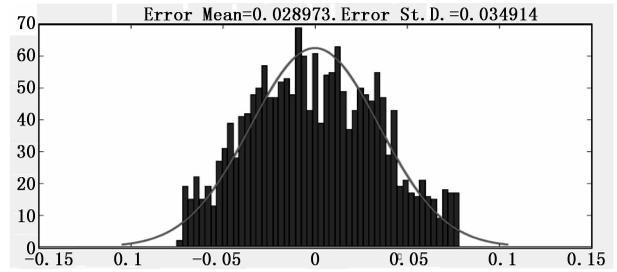


图 6 GA-ANFIS2 训练数据误差指标的统计特性

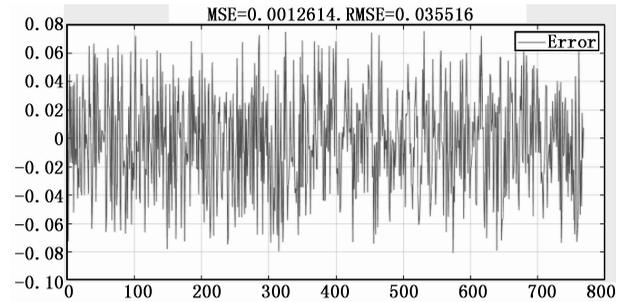


图 7 GA-ANFIS2 测试数据输出结果的误差指标

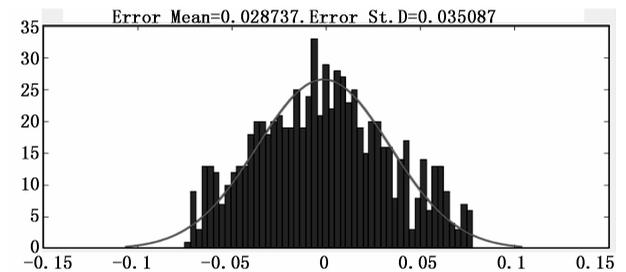


图 8 GA-ANFIS2 测试数据误差指标的统计特性

表 1 GA-ANFIS2 五次实验训练数据的误差结果

序号	均方误差	均方根误差	平均误差	误差标准差
1	0.0012183	0.034904	0.028973	0.034914
2	0.0011668	0.034159	0.028009	0.034158
3	0.0011685	0.034183	0.028156	0.034185
4	0.0011727	0.034244	0.028197	0.034249
5	0.0011983	0.034617	0.028632	0.034613
均值	0.001185	0.034421	0.028393	0.034424

表 2 GA-ANFIS2 五次实验测试数据的误差结果

序号	均方误差	均方根误差	平均误差	误差标准差
1	0.0012614	0.035516	0.028737	0.035087
2	0.0012481	0.035329	0.027963	0.034747
3	0.0012397	0.035209	0.02809	0.034883
4	0.0012448	0.035282	0.028201	0.034877
5	0.0012826	0.035813	0.029013	0.035497
均值	0.001255	0.03543	0.028401	0.035018

3.3.4 GA-ANFIS4 实验结果

GA-ANFIS4 实验中训练数据的结果见图 9、图 10，图中分别给出了输出结果的误差指标和输出结果的误差指标的统计特性。

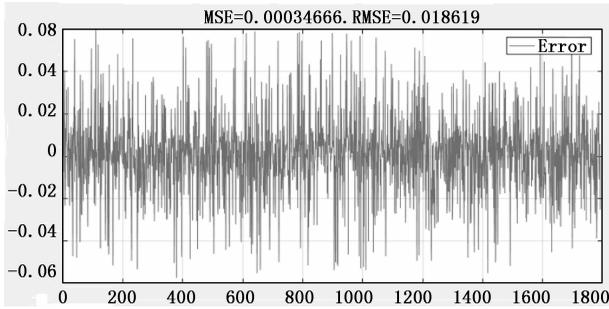


图 9 GA-ANFIS4 训练数据输出结果的误差指标

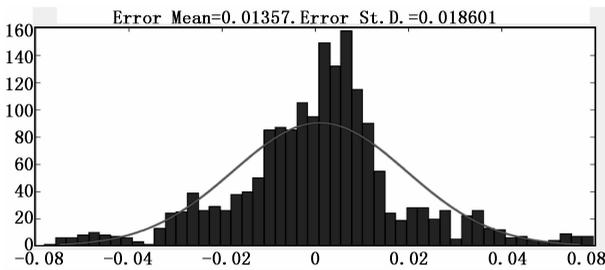


图 10 GA-ANFIS4 训练数据一阶误差的统计特性

测试数据的结果见图 11、图 12，图中分别给出了输出结果的误差指标和输出结果的误差指标的统计特性。

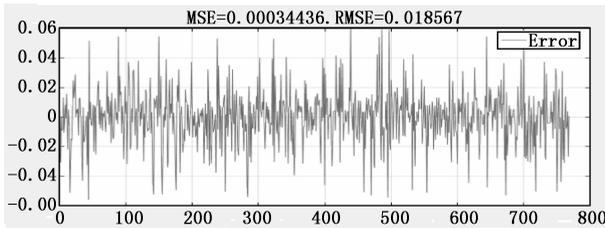


图 11 GA-ANFIS4 测试数据输出结果的误差指标

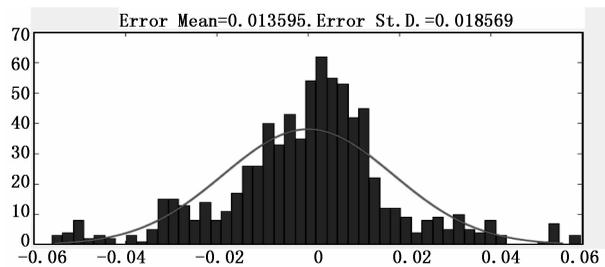


图 12 GA-ANFIS4 测试数据一阶误差的统计特性

实验中依次记录五次 GA-ANFIS 算法的均方误差、均方根误差、平均误差和误差标准差，并计算每个指标的均值，得到表 3 和表 4 所示的结果。

4.4 实验分析

下面对 4 次实验的平均误差进行比对，结果如图 13 所示。根据结果对比分析，可得到如下实验结论：

表 3 GA-ANFIS4 五次实验训练数据的误差结果

序号	均方误差	均方根误差	平均误差	误差标准差
1	0.00034666	0.018619	0.01357	0.018601
2	0.00031349	0.017706	0.013142	0.017703
3	0.00028394	0.016851	0.013039	0.016822
4	0.00036792	0.019181	0.01577	0.019109
5	0.00025389	0.015934	0.012857	0.015778
均值	0.000313	0.017658	0.013676	0.017603

表 4 GA-ANFIS4 五次实验测试数据的误差结果

序号	均方误差	均方根误差	平均误差	误差标准差
1	0.00034465	0.018557	0.013595	0.018569
2	0.00033468	0.0182974	0.013437	0.018292
3	0.00033359	0.018264	0.013361	0.01826
4	0.0004019	0.020047	0.016302	0.020058
5	0.00027214	0.016497	0.012624	0.016459
均值	0.000337	0.018332	0.013864	0.018328

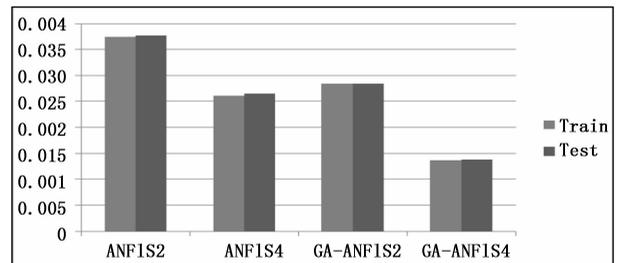


图 13 四组实验平均误差比对

1) ANFIS 模型应用于蓄电池 SOH 预测，4 组实验的平均误差均比较小，验证了采用 ANFIS 做 SOH 预测的有效性。

2) 同一组实验中，测试数据和训练数据的平均误差较为接近，说明训练中所产生的模型比较好，预测的结果符合预期。

3) 将遗传算法和自适应神经模糊系统相结合，能显著提升 ANFIS 算法模糊推理的效果。其中，GA-ANFIS2 相比 ANFIS2 测试数据误差减小 24.6%，GA-ANFIS4 相比 ANFIS4 测试数据误差减小 47.6%。

4) 采用放电深度、输出能量、温度和海拔四输入变量做蓄电池 SOH，能显著改进放电深度、输出能量两输入变量的模型预测效果。其中，ANFIS4 相比 ANFIS2 测试数据误差减小 29.7%，GA-ANFIS4 相比 GA-ANFIS2 测试数据误差减小 51.2%。

5 结束语

为保证装甲车辆演训过程中性能良好, 本文对装甲车辆中军用蓄电池的 SOH 预测问题展开研究。将遗传算法同自适应模糊神经网络相结合, 设计了一种基于 GA-ANFIS 的蓄电池 SOH 预测算法, 并在 Matlab2016b 进行实现。实验结果表明, 基于 GA 优化的 ANFIS 算法相比传统算法具有更好的优化效果。同时, 增加海拔和温度后, 四输入模型的测试数据误差明显优于两输入模型。本文设计的 GA-ANFIS 预测技术具有一定的通用性, 在改进军用蓄电池 SOH 预测效果的同时, 可作为装甲装备自动测试系统中部件状态预测的一般方法, 以提升自动测试系统的整体能力。

参考文献:

- [1] Schlasza C, Ostertag P, Chrenko D, et al. Review on the aging mechanisms in Li-ion batteries for electric vehicles based on the FMEA method, 2014; 1-6.
- [2] Gering K L, Sazhin S V, Jamison D K, et al. Investigation of path dependence in commercial lithium-ion cells chosen for plug-in hybrid vehicle duty cycle protocols [J]. Journal of Power Sources, 2011, 196 (7): 3395-3403.
- [3] Shi W, Hu X, Jin C, et al. Effects of imbalanced currents on large-format LiFePO₄/graphite batteries systems connected in parallel [J]. Journal of Power Sources, 2016, 313: 198-204.
- [4] Micea M V, Ungurean L, Carstoiu G N, et al. Online state-of-health assessment for battery management systems [J]. IEEE Trans. Instrum. Meas. 2011, 60 (6): 1997-2006.
- [5] Ng K S, Huang Y F, Moo C S, et al. An enhanced coulomb counting method for estimating state-of-charge and state-of-health of lead-acid batteries [A]. INTELEC 2009 31st int telecommun energy conference [C]. 2009: 1-5.
- [6] Dong G, Wei J, Zhang C, Chen Z. Online state of charge estimation and open circuit voltage hysteresis modeling of LiFePO₄ battery using invariant imbedding method [J]. Appl. Energy, 2016, 162: 163-71.
- [7] Raman S R, Saritha B, John V. Computationally efficient and accurate modeling of Li-ion battery [A]. 2013 IEEE Innov. Smart Grid Technol (ISGT Asia) [C]. 2013: 1-6.
- [8] Dubarry M, Truchot C, Liaw B Y. Synthesize battery degradation modes via adiaagnostic and prognostic model [J]. Power Sources, 2012, 219: 204-216.
- [9] Chaoui H, Golbon N, Hmouz I, et al. Lyapunov-based adaptive state of charge and state of health estimation for lithium-ion batteries [J]. IEEE Trans. Ind. Electron., 2015; 62 (3).
- [10] Chao H, Gaurav J, Puqiang Z. Data-driven method based on particle swarm optimization and k-nearest neighbor regression for estimating capacity of lithium-ion battery [J]. Appl. Energy, 2014, 129: 49-55.
- [11] Jin F, Yongling H, Guofu W. Comparison study of equivalent circuit model of Li-ion battery for electrical vehicles [J]. Res. J. Appl. Sci. Eng. Technology, 2013, 6 (20): 3756-9.
- [12] Ouyang M, Feng X, Han X, et al. A dynamic capacity degradation model and its applications considering varying load for a large format Li-ion battery [J]. Appl Energy, 2016, 165: 48-59.
- [13] Eddahech A, Briat O, Bertrand N, et al. Behavior and state-of-health monitoring of Li-ion batteries using impedance spectroscopy and recurrent neural networks [J]. Int J Elect Power Energy System, 2012; 42: 487e94.
- [14] Zenati A, Desprez P, Razik H, Rael S. Impedance measurements combined with the fuzzy logic methodology to assess the SOC and SOH of lithium-ion cells [A]. 2010 IEEE Veh. Power Propuls. Conf [C]. IEEE, 2010.
- [15] Claudio B M, Marcos O E, et al. Particle-filtering-based estimation of maximum available power state in lithium-ion batteries [J]. Appl Energy, 2016, 161: 349-363.
- [16] Patil M A, Tagade P, Hariharan S K, et al. A novel multi-stage support vector machine based approach for Li ion battery remaining useful life estimation [J]. Appl. Energy, 2015; 159: 285-297.
- [17] Zou Y, Hu X, Ma H, et al. Combined state of charge and state of health estimation over lithium-ion battery cell cycle lifespan for electric vehicles [J]. Power Sources, 2015; 273: 793-803.
- [18] Hu C, Jain G, Zhang P, et al. Data-driven method based on particle swarm optimization and k-nearest neighbor regression for estimating capacity of lithium-ion battery [J]. Appl. Energy, 2014, 129 (15): 49-55.
- [19] 唐骏宇, 冯长江. 基于模糊辨识的蓄电池 SOH 测量方法 [J]. 电源技术, 2018, 42 (2): 244-246.
- [20] 李刚, 谢永成, 李光升, 等. 基于自适应神经网络模糊推理系统的蓄电池 SOH 预测 [J]. 微型机与应用, 2011, 30 (22): 82-84.
- [21] 孙淑梅. 阀控密封式铅酸蓄电池监测技术探讨 [J]. 电源世界, 2012 (2): 48-51.
- [22] 张红润, 李军鸿. 铅酸蓄电池使用寿命影响因素与电池失效原因 [J]. 机电产品开发与创新, 2010 (5): 60-61.
- [23] 江海. 蓄电池智能在线监测系统的研究与设计 [D]. 哈尔滨: 哈尔滨理工大学, 2007.
- [24] 蔡滨, 李斐如, 马巍, 等. 高原高寒环境对军用特种车辆蓄电池性能的影响及其维护 [J]. 军事交通学院学报, 2014, 16 (8): 48-52.