

1. 基于集成模型的锂离子电池寿命预测方法,其特征是:它由以下步骤实现:

步骤一、对电池循环充放电试验测试数据进行预处理,得到等压降时间序列作为输入数据集和锂离子电池剩余容量序列作为输出数据集;将原始数据集分为训练数据集 Train dataset 和测试数据集 Test dataset;

步骤二、采用 Bagging 算法对训练数据集 Train dataset 进行二次重采样,得到 T 个新的训练集;

步骤三、建立单调回声状态网络模型,所述单调回声状态网络模型中输入维数为 L、储备池规模为 N 和输出维数为 M;L、N 和 M 均为正整数;

步骤四、初始化单调回声状态网络内部连接权值,重复步骤四一至步骤四三 T 次,得到 T 个未经训练的单调回声状态网络子模型;T 为正整数;

步骤四一、随机建立 $N \times L$ 维输入权值矩阵 W^{in} , $N \times N$ 维内部连接权值矩阵 W_0 和 $N \times M$ 维反馈权值矩阵 W^{back} ;

步骤四二、根据公式:

$$W_1 = W_0 / |\lambda_{\max}|$$

获得 W_1 ,其中 $|\lambda_{\max}|$ 是 W_0 的最大特征值的绝对值,此时 W_1 的谱半径为 1;

步骤四三、根据公式:

$$W = \alpha W_1$$

式中: $\alpha < 1$;

此时内部连接权值具有小于 1 的谱半径,完成一次未经训练的单调回声状态网络子模型的建立;

步骤五、设置单调回声状态网络模型的第一自由参数集,所述第一自由参数集包括储备池规模 N_1 、谱半径 sr_1 、输入单元尺度 IS_1 和输入单元位移 IF_1 ,使其满足单调回声状态网络输出 RUL 预测值大于 RUL 真实值,并使得 T/2 个单调回声状态网络模型的自由参数集为第一自由参数集;

设置单调回声状态网络模型的第二自由参数集,,所述第二自由参数集包括储备池规模 N_2 、谱半径 sr_2 、输入单元尺度 IS_2 和输入单元位移 IF_2 ,使其满足 MONESN 输出 RUL 预测值小于 RUL 真实值;使得剩余的 T/2 个单调回声状态网络模型的自由参数集为第二自由参数集;

步骤六、集成单调回声状态网络模型的输出 RUL_i ,并采用测试数据集 Test dataset 驱动集成单调回声状态网络模型,根据公式:

$$RUL_F = \frac{1}{T} \sum_{i=1}^T RUL_i$$

获得锂离子电池剩余寿命预测值 RUL_F ,完成基于集成模型的锂离子电池寿命预测。

2. 根据权利要求 1 所述的基于集成模型的锂离子电池寿命预测方法,其特征在于采用 Bagging 算法对训练数据集 Train dataset 进行二次重采样,得到 T 个新的训练集的具体方法是:

步骤 A1、给定训练数据集 Train dataset = $\{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$,使用基本学习算法为 f,建立 T 个子模型;

步骤 A2、开始第 i 次重采样, i 的初始值为 1;

步骤 A3、从训练数据中采用有放回的均匀抽样得到和原始训练数据集等大小的新的数据集 D_{b_i} , 并使用 D_{b_i} 驱动学习算法得到子模型 f_i ;

步骤 A4、判断 i 是否小于或等于 T , 如果判断结果为是, 则令 i 的值加 1, 并返回执行步骤 A3; 如果判断结果为否, 则执行步骤 A5;

步骤 A5、集成输出:

$$f = \sum_{i=1}^T \alpha_i f_i, \alpha_i = \frac{1}{T} \quad \circ$$

基于集成模型的锂离子电池寿命预测方法

技术领域

[0001] 本发明涉及一种锂离子电池寿命预测方法。

背景技术

[0002] 单调回声状态网络虽然从预测精度上对锂离子电池剩余寿命预测进行改善,但是由于回声状态网络的自由参数的设置缺乏严密的理论体系的指导,所以想要得到预先设置的预测精度,必须使用交叉验证或者专家经验的方法得到回声状态网络的参数,但是这种方法繁琐而且费时。而且由于神经网络内部的不透明性,导致输出的不稳定性,这将大大限制单调回声状态网络的应用。

发明内容

[0003] 本发明是为了解决现有的锂离子电池寿命预测适用性低、稳定性差的问题,从而提供一种基于集成模型的锂离子电池寿命预测方法。

[0004] 基于集成模型的锂离子电池寿命预测方法,它由以下步骤实现:

[0005] 步骤一、对电池循环充放电试验测试数据进行预处理,得到等压降时间序列作为输入数据集和锂离子电池剩余容量序列作为输出数据集;将原始数据集分为训练数据集 Train dataset 和测试数据集 Test dataset;

[0006] 步骤二、采用 Bagging 算法对训练数据集 Train dataset 进行二次重采样,得到 T 个新的训练集;

[0007] 步骤三、建立单调回声状态网络模型,所述单调回声状态网络模型中输入维数为 L、储备池规模为 N 和输出维数为 M;L、N 和 M 均为正整数;

[0008] 步骤四、初始化单调回声状态网络内部连接权值,重复步骤四一至步骤四三 T 次,得到 T 个未经训练的单调回声状态网络子模型;

[0009] 步骤四一、随机建立 $N \times L$ 维输入权值矩阵 W^{in} , $N \times N$ 维内部连接权值矩阵 W_0 和 $N \times M$ 维反馈权值矩阵 W^{back} ;

[0010] 步骤四二、根据公式:

$$[0011] \quad W_1 = W_0 / |\lambda_{\max}|$$

[0012] 获得 W_1 , 其中 $|\lambda_{\max}|$ 是 W_0 的最大特征值的绝对值,此时 W_1 的谱半径为 1;

[0013] 步骤四三、根据公式:

$$[0014] \quad W = \alpha W_1$$

[0015] 式中: $\alpha < 1$;

[0016] 此时内部连接权值具有小于 1 的谱半径,完成一次未经训练的单调回声状态网络子模型的建立;

[0017] 步骤五、设置单调回声状态网络模型的第一自由参数集,所述第一自由参数集包括储备池规模 N_1 、谱半径 sr_1 、输入单元尺度 IS_1 和输入单元位移 IF_1 ,使其满足单调回声状态网络输出 RUL 预测值大于 RUL 真实值,并使得 T/2 个单调回声状态网络模型的自由参数

集为第一自由参数集；

[0018] 设置单调回声状态网络模型的第二自由参数集,所述第二自由参数集包括储备池规模 N_2 、谱半径 sr_2 、输入单元尺度 IS_2 和输入单元位移 IF_2 ,使其满足 MONESN 输出 RUL 预测值小于 RUL 真实值;使得剩余的 $T/2$ 个单调回声状态网络模型的自由参数集为第二自由参数集;

[0019] 步骤六、集成单调回声状态网络模型的输出 RUL_i ,并采用测试数据集 Test dataset 驱动集成单调回声状态网络模型,根据公式:

$$[0020] \quad RUL_F = \frac{1}{T} \sum_{i=1}^T RUL_i$$

[0021] 获得锂离子电池剩余寿命预测值,完成基于集成模型的锂离子电池寿命预测。

[0022] 采用 Bagging 算法对训练数据集 Train dataset 进行二次重采样,得到 T 个新的训练集的具体方法是:

[0023] 步骤 A1、给定训练数据集 Train dataset = $\{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$,使用基本学习算法为 f ,建立 T 个子模型;

[0024] 步骤 A2、开始第 i 次重采样, i 的初始值为 1;

[0025] 步骤 A3、从训练数据中采用有放回的均匀抽样得到和原始训练数据集等大小的新的数据集 D_{bi} ,并使用 D_{bi} 驱动学习算法得到子模型 f_i ;

[0026] 步骤 A4、判断 i 是否小于或等于 T ,如果判断结果为是,则令 i 的值加 1,并返回执行步骤 A3;如果判断结果为否,则执行步骤 A5;

[0027] 步骤 A5、集成输出:

$$[0028] \quad f = \sum_{i=1}^T \alpha_i f_i, \alpha_i = \frac{1}{T} \quad .$$

[0029] 本发明提升预测方法的适用性和稳定性,同时本发明能够进行间接预测,能够应用在空间卫星的锂离子电池上。

附图说明

[0030] 图 1 是本发明的基于集成模型的锂离子电池寿命预测方法的流程示意图;其中标记 A 为集成子模型建立过程;标记 B 为集成子模型精简过程;标记 C 为集成子模型融合过程;

[0031] 图 2 是集成单调回声状态网络模型的示意图;

[0032] 图 3 是基于集成单调回声状态网络的锂离子电池 RUL 预测方法流程示意图;

[0033] 图 4 是 NASA 锂离子电池等压降放电时间序列仿真示意图;

[0034] 图 5 是 NASA 锂离子电池剩余容量序列仿真示意图;

[0035] 图 6 是 MONESN 子模型的剩余容量预测及集成预测仿真示意图;其中:标记 61 为开始预测点;标记 62 为剩余容量真实值;标记 63 为剩余容量预测值;标记 64 为第 25 个 MONESN 预测值;标记 65 为第 45 个 MONESN 预测值;标记 66 为第 75 个 MONESN 预测值;标记 67 为第 95 个 MONESN 预测值;

[0036] 图 7 是基于集成 MONESN 的 NASA 锂离子电池剩余寿命预测仿真示意图;标记 71 为

开始预测点 ; 标记 72 为剩余容量真实值 ; 标记 73 为剩余容量预测值 ;

[0037] 图 8 是基于单个 MONESN 的 NASA 锂离子电池剩余寿命预测仿真示意图 ; 标记 81 为开始预测点 ; 标记 82 为剩余容量真实值 ; 标记 83 为剩余容量预测值。

具体实施方式

[0038] 具体实施方式一、基于集成模型的锂离子电池寿命预测方法, 它由以下步骤实现 :

[0039] 步骤一、对电池循环充放电试验测试数据进行预处理, 得到等压降时间序列作为输入数据集和锂离子电池剩余容量序列作为输出数据集 ; 将原始数据集分为训练数据集 Train dataset 和测试数据集 Test dataset ;

[0040] 步骤二、采用 Bagging 算法对训练数据集 Train dataset 进行二次重采样, 得到 T 个新的训练集 ;

[0041] 步骤三、建立单调回声状态网络模型, 所述单调回声状态网络模型中输入维数为 L、储备池规模为 N 和输出维数为 M ; L、N 和 M 均为正整数 ;

[0042] 步骤四、初始化单调回声状态网络内部连接权值, 重复步骤四一至步骤四三 T 次, 得到 T 个未经训练的单调回声状态网络子模型 ;

[0043] 步骤四一、随机建立 $N \times L$ 维输入权值矩阵 W^{in} , $N \times N$ 维内部连接权值矩阵 W_0 和 $N \times M$ 维反馈权值矩阵 W^{back} ;

[0044] 步骤四二、根据公式 :

$$[0045] \quad W_1 = W_0 / |\lambda_{\max}|$$

[0046] 获得 W_1 , 其中 $|\lambda_{\max}|$ 是 W_0 的最大特征值的绝对值, 此时 W_1 的谱半径为 1 ;

[0047] 步骤四三、根据公式 :

$$[0048] \quad W = \alpha W_1$$

[0049] 式中 : $\alpha < 1$;

[0050] 此时内部连接权值具有小于 1 的谱半径, 完成一次未经训练的单调回声状态网络子模型的建立 ;

[0051] 步骤五、设置单调回声状态网络模型的第一自由参数集, 所述第一自由参数集包括储备池规模 N_1 、谱半径 sr_1 、输入单元尺度 IS_1 和输入单元位移 IF_1 , 使其满足单调回声状态网络输出 RUL 预测值大于 RUL 真实值, 并使得 T/2 个单调回声状态网络模型的自由参数集为第一自由参数集 ;

[0052] 设置单调回声状态网络模型的第二自由参数集, 所述第二自由参数集包括储备池规模 N_2 、谱半径 sr_2 、输入单元尺度 IS_2 和输入单元位移 IF_2 , 使其满足 MONESN 输出 RUL 预测值小于 RUL 真实值 ; 使得剩余的 T/2 个单调回声状态网络模型的自由参数集为第二自由参数集 ;

[0053] 步骤六、集成单调回声状态网络模型的输出 RUL_i , 并采用测试数据集 Test dataset 驱动集成单调回声状态网络模型, 根据公式 :

$$[0054] \quad RUL_F = \frac{1}{T} \sum_{i=1}^T RUL_i$$

[0055] 获得锂离子电池剩余寿命预测值, 完成基于集成模型的锂离子电池寿命预测。

[0056] 采用 Bagging 算法对训练数据集 Train dataset 进行二次重采样,得到 T 个新的训练集的具体方法是:

[0057] 步骤 A1、给定训练数据集 Train dataset = $\{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$, 使用基本学习算法为 f, 建立 T 个子模型;

[0058] 步骤 A2、开始第 i 次重采样, i 的初始值为 1;

[0059] 步骤 A3、从训练数据中采用有放回的均匀抽样得到和原始训练数据集等大小的新的数据集 D_{b_i} , 并使用 D_{b_i} 驱动学习算法得到子模型 f_i ;

[0060] 步骤 A4、判断 i 是否小于或等于 T, 如果判断结果为是, 则令 i 的值加 1, 并返回执行步骤 A3; 如果判断结果为否, 则执行步骤 A5;

[0061] 步骤 A5、集成输出:

$$[0062] \quad f = \sum_{i=1}^T \alpha_i f_i, \alpha_i = \frac{1}{T} \quad .$$

[0063] 原理: 本发明中的集成学习方法:

[0064] 集成学习是指将多个模型融合完成预测问题的方法, 它降低了对单个模型预测精度的要求, 而且与单个模型相比从预测精度和稳定性两方面都有一定程度的提高。由此, 本发明将使用集成单调回声状态网络的方法预测锂离子电池的剩余寿命。

[0065] 集成学习定义: 集成学习是使用一系列模型同时对同一个问题进行学习的过程。最终, 将这些模型用某一种算法集成作为最终的预测输出。集成学习过程被分为集成子模型建立, 集成子模型精简和集成子模型融合三部分, 如图 1 所示。在集成子模型建立阶段, 建立一系列预测子模型 (K_0 个子模型, $f_1, f_2, f_3, f_4, \dots, f_{k_0}$)。在子模型的建立的过程中, 有可能存在冗余的子模型 (如 f_2, f_4 等), 通过集成子模型精简阶段消除冗余的子模型。最终, 在集成子模型融合阶段采用集成方法 (f_e 表示融合方法) 将精简后的剩余子模型融合作为集成的最终输出 (由 f_f 表示集成输出)。集成子模型精简目的是在不降低预测精度的同时减少算法的计算量, 没有集成子模型精简步骤的集成方法是集成方法的一种特殊形式, 称为直接集成方法。

[0066] 集成学习过程: Rooney 等人提出集成学习主要解决两个问题: (1) 怎样建立可用于集成的子模型, 和 (2) 怎样融合集成子模型。集成子模型精简的目的是提高预测性能或减少计算量。到目前为止, 有非常多的文献针对集成学习完成研究, 所以集成过程的每一个步骤都有多种方法, 本文首先将针对直接集成方法进行简要介绍。

[0067] 集成子模型建立: 集成子模型建立阶段是建立一系列用于集成的子模型, 如公式 (1) 所示。

$$[0068] \quad F_0 = \{f_i, i = 1, 2, \dots, K_0\} \quad (1)$$

[0069] 其中, F_0 表示由 K_0 个子模型组成的子模型库, f_i 表示子模型。如果用于预测的子模型都是同一种子模型, 称之为同态集成学习。如果使用各种不同的子模型进行集成, 称为异态集成学习。

[0070] 为了建立完成集成子模型的建立, 首先需要知道集成子模型具有何种性质才能保证集成方法的有效性。我们知道, 集成方法的提出是用于提高预测的精度, 体现为模型泛化误差的减小, 那么最直接的方法就是将集成泛化误差分解寻找集成子模型之间的关系。泛

化误差通常用均方误差 (Mean Squared Error, MSE) 表示, 如公式 (2) 所示。其中 f_F 是由 K_0 个子模型集成的输出, $f_F = \sum_{i=1}^{K_0} \alpha_i f_i$, 其中 $\alpha_i \geq 0$ 且 $\sum_{i=1}^{K_0} \alpha_i = 1$, 所以 MSE 近似等于 K_0 个子模型预测输出和真实值误差的平方, 如公式 (3) 所示。

[0071] 针对神经网络的集成, Brown 提出一种通用的 MSE 的分解方法, 称为偏差 / 方差分解法, 如公式 (4) 和 (5) 所示。

$$[0072] \quad \text{MSE}(f_F) = E[(f_F - f)^2] \quad (2)$$

$$[0073] \quad \text{MSE}(f_F) \approx \left(\sum_{i=1}^{K_0} \alpha_i \times (f_i - f) \right)^2 \quad (3)$$

$$[0074] \quad E[(f_F - f)^2] = [E(f_F) - E(f)]^2 + E\{[f_F - E(f_F)]^2\} \quad (4)$$

$$[0075] \quad \text{MSE}(f_F) = \text{bias}(f_F)^2 + \text{var}(f_F) \quad (5)$$

$$[0076] \quad \text{MSE}(f_F) = \sum_{i=1}^{K_0} [\alpha_i \times (f_i - f)^2] - \sum_{i=1}^{K_0} [\alpha_i \times (f_i - f_F)^2] \quad (6)$$

[0077] 将公式 (4) 分解为公式 (5) 等号右边所示的偏差和方差两项。分别表示测量值和真实值之间的距离和预测值的方差。将公式 (3) 带入公式 (5) 得到公式 (6), 由于等式右边第二项非负, 所以可以证明集成的泛化误差小于或者等于子模型库中随机选择的任意一个子模型的泛化误差。由公式 (6) 可以知道, 当方差项越大的时候, 集成的泛化误差越小。也就是说, 子模型之间的差异越大, 集成的泛化误差越小。由此, 可以得到一个重要的结论: 集成子模型预测准确性和多样性是满足集成泛化误差减小的条件。但是准确性和多样性是两个互相矛盾的指标, 所以集成方法是采用多模型的多样性降低对单个模型准确性的要求, 同时达到预测泛化误差的减小, 那么就需要采用方法试图达到准确性和多样性之间的一个好的折中。在集成子模型建立过程中, 主要通过操纵数据或者通过操纵模型参数两种方法。

[0078] (1) 操纵数据方法

[0079] 操纵数据方法主要是通过对原始训练数据集二次采样, 并且假定学习算法不稳定, 也就是说, 当原始数据集有微小的改变时会导致子模型输出的明显改变。神经网络, 决策树等方法都是典型的不稳定算法。典型的数据集二次采样方法包括 Bagging 和 Boosting 两种。

[0080] Bagging 是 Bootstrap Aggregating 的缩写, 正如它的名字的含义, Bagging 包含两部分: Bootstrap 是引导的意思, 表示二次采样后建立不同的子模型, 假设训练数据集中含有 m 个训练样本, 从 m 个训练样本中采用有放回的均匀抽样。由此得到一个和原始训练数据集规模相等或者小于原始数据集的的样本集, 新的样本集中有些原始数据出现的次数多余一次, 而有的原始数据子子模型中则没有出现。重复 T 次重采样过程, 得到 T 个新的样本集。然后采用每一个新样本集驱动学习算法, 得到一个含有 T 个子模型的子模型库。Aggregating 是聚合的意思, 表示将多个重采样的输出聚合。对于分类问题, Bagging 算法采用投票方法决定子模型的最终输出, 对于回归问题, Bagging 算法将多子模型输出求均值作为集成输出。

[0081] Boosting 算法是针对分类问题设计的, 后来改进的 AdaBoost.R 算法用于回归问题。初始化时将训练数据被选中的权值设为 $1/m$, 重采样后得到新的训练数据集, 记录子模型预测每个样本的误差并作为下一次样本被选中的概率的计算依据, 误差较大的样本在新训练样本集中被选中的概率较大, 重采样后得到新的训练数据集, 如此循环得到 T 个子模

型,同样预测子模型也有权重,预测好的子模型权值大。采用加权平均的方法得到集成输出。Boosting 算法可以将一个比随机预测略好的预测模型转化为高精度的预测模型,但是很有可能将预测偏向于个别困难样本,因此,方法有时效果很好,有时却很不好。

[0082] (2) 操作模型参数

[0083] 操作模型参数是通过将子模型的参数初始化为不同的值,从而得到多样化的子模型的方法。神经网络的集成通常使用操作模型参数的方法,有的通过初始化设置不同的隐层数,以及不同的节点数量,有的则通过初始化不同的连接权值,由此得到最终的模型可能会存在非常显著的不同。

[0084] 集成子模型融合:子模型库建立完成之后,下一步需要完成的是将多个子模型输出融合得到一个集成输出。集成子模型融合的方法主要有分为基本集成方法和泛化集成方法。

[0085] 基本集成方法是计算集成子模型的平均值,如公式 (7) 所示,这种方法不依赖于子模型也不依赖于训练数据,使用基本集成方法的前提是子模型的误差是相互独立的而且误差的均值为零。

$$[0086] \quad f_F = \frac{1}{T} \sum_{i=1}^T f_i \quad (7)$$

[0087] 泛化集成方法是对集成子模型加权得到,其中子模型的权值和误差的大小成反比。如公式 (8) 所示。采用 Bagging 算法中 36.8% 没有出现在新的数据集的数据作为验证数据集,计算子模型的预测误差,从而得到和误差成反比的权值 w_i 。

$$[0088] \quad f_F = \sum_{i=1}^T w_i f_i \quad (8)$$

[0089] 但是由于验证集不能完全表示测试集中的信息,所以泛化集成方法会增加过拟合的概率,这个问题通过交叉验证过程得以改善。

[0090] 值得一提的是,集成算法虽然得到越来越多的关注,集成算法的每一个步骤都有很多基本方法及其改进,然而针对一个给定的回归问题,应该使用哪种集成算法,却没有一个明确的指导。

[0091] 基于 Ensemble MONESN 的锂离子电池 RUL 预测方法:为了解决单调回声状态网络输出不稳定,而且降低对单个单调回声状态网络精度要求的问题,研究基于集成的单调回声状态网络的锂离子电池剩余寿命预测方法,通过不同的单调回声状态网络子模型对训练数据集的不同区域进行学习,并将结果进行融合,实现锂离子电池剩余寿命更加精确而且稳定的预测。

[0092] 集成单调回声状态网络的建立:集成单调回声状态网络的模型框图如图 2 所示。

[0093] 首先,回声状态网络是一种新型的递归神经网络,它采用大规模稀疏连接的储备池代替原始神经网络的隐层,随机初始化建立输入权值和储备池内部连接权值,实现集成子模型建立中操纵模型参数方法中通过初始化不同权值建立多样性的回声状态网络子模型;

[0094] 其次,由于神经网络是典型的不稳定的学习算法,所以使用 bagging 算法对原始训练数据集进行二次重采样得到多个新训练数据集,采用新的训练数据集驱动单调回声状态网络,得到的单调回声状态网络具有多样性。

[0095] 最终,调整回声状态网络子模型的自由参数,使得子模型的输出大约一半大于真实值,另一半小于真实值,由于子模型的误差均值近似为零,所以通过基本集成方法将子模型库中的子模型集成,得到的集成输出的泛化误差将大大减小。同时降低了单个回声状态网络的预测精度要求。

[0096] Ensemble MONESN 的锂离子电池 RUL 预测实验及分析:

[0097] 根据对基于集成单调回声状态网络的锂离子电池 RUL 预测框架的描述,以下采用 NASA AMES PCoE 研究中心提供的锂离子电池退化状态监测数据进行实验验证,以证明基于集成回声状态网络的锂离子电池剩余寿命预测方法的有效性。集成单调回声状态网络主要从预测稳定性和预测准确性方面相对单个单调回声状态网络有了一定的改进,所以本发明采用如下四种误差评价标准来评估算法的有效性。

[0098] 其中 $f(u_i)$ 表示锂离子电池剩余容量真实值, $f'(u_i)$ 表示剩余容量预测值, $\bar{f}(u_i)$ 表示剩余容量预测均值, m 表示数据集中含有的样本的个数。 $RUL_{\text{predict},i}$ 表示第 i 个单调回声状态网络子模型的锂离子电池 RUL 预测值, RUL_{true} 表示 RUL 真实值, T 表示子模型库中共含有 T 个单调回声状态网络子模型。

[0099] (1) 均方误差 (Root Mean Square Error, RMSE): 评价局部预测精度。

$$[0100] \quad RMSE = \sqrt{\frac{\sum_{i=1}^m (f(u_i) - f'(u_i))^2}{m}} \quad (9)$$

[0101] (2) R^2 : 评价整体预测效果, R^2 越接近 1, 说明预测越准确。

$$[0102] \quad R^2 = 1 - \frac{\sum_{i=1}^m (f(u_i) - f'(u_i))^2}{\sum_{i=1}^m (f(u_i) - \bar{f}(u_i))^2} \quad (10)$$

[0103] (3) 剩余寿命预测误差 (RUL_{error}), 评价 RUL 预测的准确性。

$$[0104] \quad RUL_{\text{error}} = RUL_{\text{predict}} - RUL_{\text{true}} \quad (11)$$

[0105] (4) 标准差 (Standard Deviation, Std): 用来度量单个回声状态网络 RUL 预测值和 RUL 真实值之间的偏离程度, 评价 RUL 预测的稳定性。

$$[0106] \quad Std = \sqrt{\sum_{i=1}^T (RUL_{\text{predict},i} - RUL_{\text{true}})^2} \quad (12)$$

[0107] NASA 锂离子电池 RUL 预测实验:

[0108] 本节采用 NASA AMES PCoE 研究中心提供的公开数据集中的 18 号电池 (Battery18) 进行 RUL 预测实验, 按照锂离子电池 RUL 预测框架, 首先进行原始数据预处理, 得到等压放电时间序列和锂离子电池剩余容量序列, 如图 4 和图 5 所示。

[0109] 本发明采用锂离子电池等压降时间序列作为单调回声状态网络模型的输入, 预测锂离子电池的剩余容量, 从而外推锂离子电池充放电剩余循环周期, 即锂离子电池剩余寿命 (RUL)。设剩余容量下降到额定容量的 75% 时锂离子电池失效, 则 Battery18 的失效阈值为 $1.8550 \times 0.75 = 1.3912\text{Ah}$ 。原始数据共有 132 个数据点, 等压放电时间序列和剩余容量序列的 1-66 点作为原始训练数据, 67-132 点作为原始测试数据。

[0110] 对于原始训练数据集, 采用 bagging 算法得到 T 个 (本节 $T = 100$) 新的训练数据集, Bagging 算法的具体流程参考前述。对于每一个新的数据集来说, 大约含有原始数据

集中 63.2% 的样本,其余 36.8% 的样本是重复的,在本实验中,将重复的数据去掉,即新的数据集中大约含有原始数据的 63.2%。如图 4 和图 5 所示,采用锂离子电池的等压降时间序列预测对应充放电周期的剩余容量序列,所以它们之间存在一一对应的关系。也就是说,MONESN 含有 $L = 1$ 维的输入向量, $M = 1$ 维的输出向量,储备池规模 N 在后续自由参数集中设置。由此随机建立了 100 个单调回声状态网络。将采用 Bagging 算法得到的 100 个新的数据集作为训练数据集驱动单调回声状态网络模型。

[0111] 采用交叉验证的方法,根据单调回声状态网络子模型的输出调整自由参数集的设置,使得大约 $T/2 = 50$ 个子模型的预测输出大于真实值,得到 $N_1 = 10$, $sr_1 = 0.2$, $IS_1 = 0.001$, $IF_1 = 0.8$ 。剩余 $T/2$ 个子模型的预测输出小于真实值,得到 $N_2 = 10$, $sr_2 = 0.5$, $IS_2 = 0.01$, $IF_2 = 0.1$ 。图 6 所示为随机选择的包含第 25, 45, 75, 95 四个单调回声状态网络子模型的剩余寿命预测结果。可以很明显的看出来,这四个子模型的预测精度不符合我们要求的精度,但是他们满足均匀的分布在真实数据的附近的条件,达到这样的精度很显然大大简化了交叉验证求取最优自由参数集的过程。

[0112] 如图 6 所示第 45 个子模型和第 95 个子模型的输出大于真实值,第 25 和子模型和第 75 个子模型的输出小于真实值,将这些子模型的输出求均值,中和多模型的误差,得到图中标记 73 所示的集成单调回声状态网络的剩余容量预测值,如图 7 所示。图中标记 72 表示剩余容量的真实值,标记 71 表示开始预测点,在开始预测点之后出现的标记 73 表示剩余容量预测值。

[0113] 在图 7 中可以看到,剩余容量和失效阈值的交点对应锂离子电池失效点。从开始预测点到电池失效点之间的循环周期为锂离子电池的剩余寿命。可以看到剩余寿命的预测值等于剩余寿命的真实值。图 8 所示为基于单个 MONESN 的 NASA 锂离子电池剩余寿命预测,可以看到,本次剩余容量预测非常准确,但是遗憾的是,由于神经网络固有的不稳定性导致单个 MONESN 的预测有时会出现非常离谱的预测。

[0114] 表 1 基于单个 MONESN 和集成 MONESN 的 NASA 锂离子电池 RUL 预测性能对比

性能评价	MONESN 单次结果	En_MONESN 单次结果	MONESN 100 次统计结果	En_MONESN 100 次统计结果
[0115] <i>RMSE</i>	0.0134	0.0133	0.0455	0.0134
<i>R²</i>	0.86624	0.9001	0.5823	0.8986
<i>RUL_{error}</i>	-2	0	-7	0
<i>Std</i>	--	--	100.4341	5.2915

[0116] 表 1 所示的两种预测方法的性能对比。其中 MONESN 表示单调回声状态网络,En_MONESN 表示集成的 MONESN 模型。采用前面描述的 4 种误差评价方法,可以看到集成单调回声网络相比于性能较好的单个 MONESN 在预测精度上略有提升。稳定性的提高可以从 RUL 预测的方差上明确观察到,集成 MONESN 预测相比于单个 MONESN 的 100 统计结果可以看到单个 MONESN 的 RUL 预测方法是集成 MONESN 的 RUL 预测方差的 20 倍。锂离子电池 RUL 预测的稳定性得到显著提高。

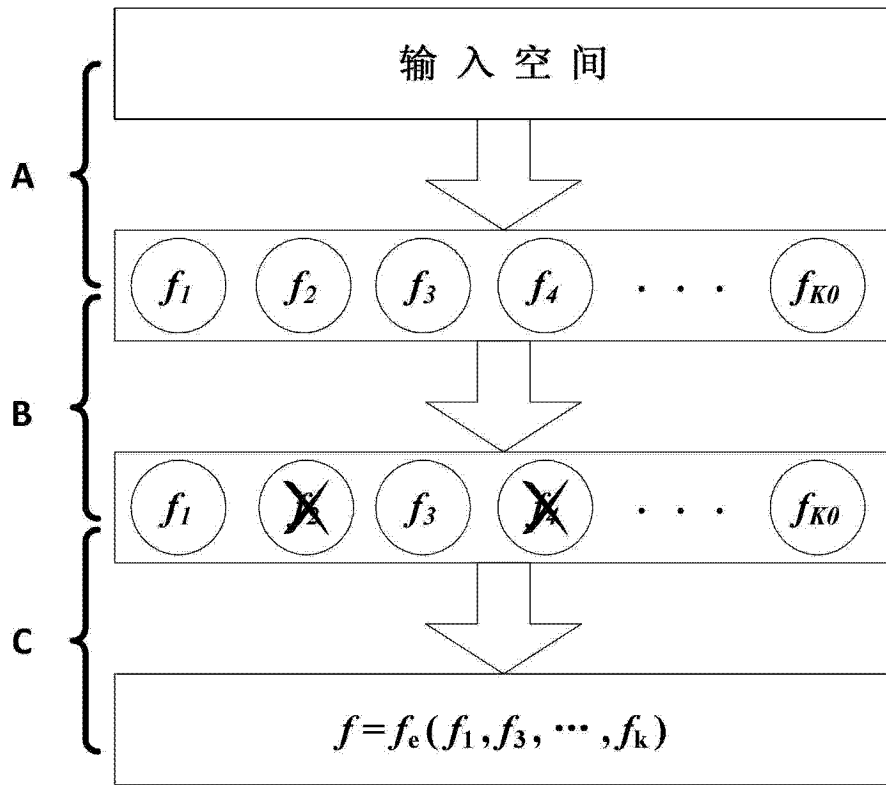


图 1

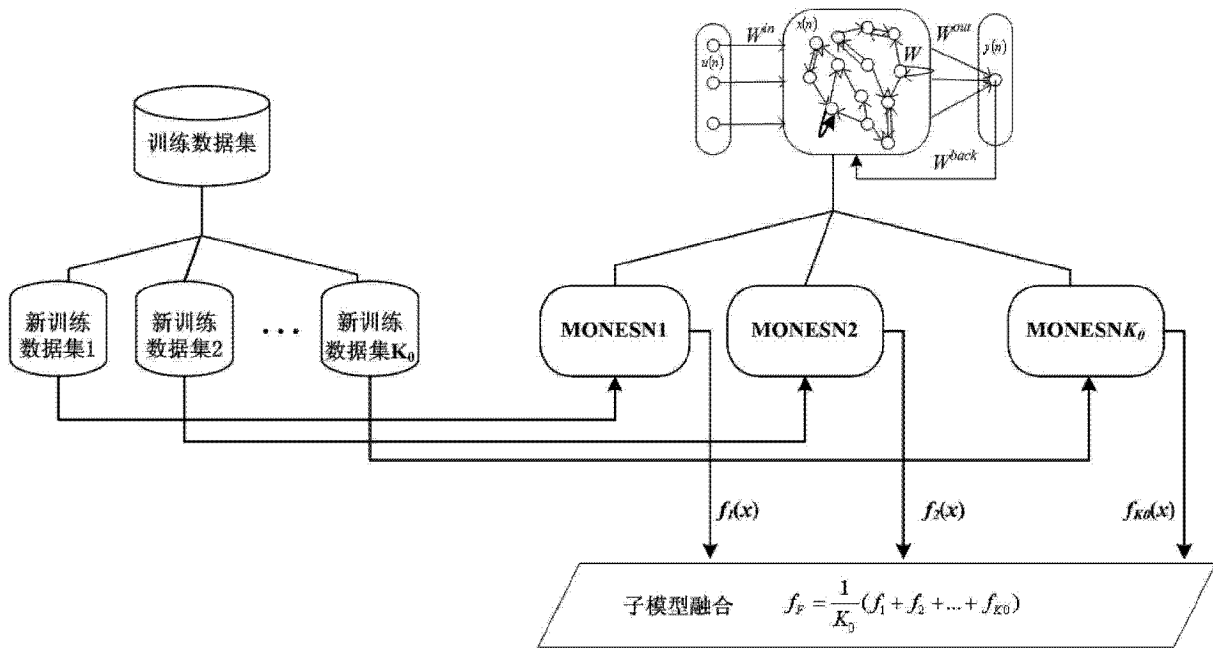


图 2

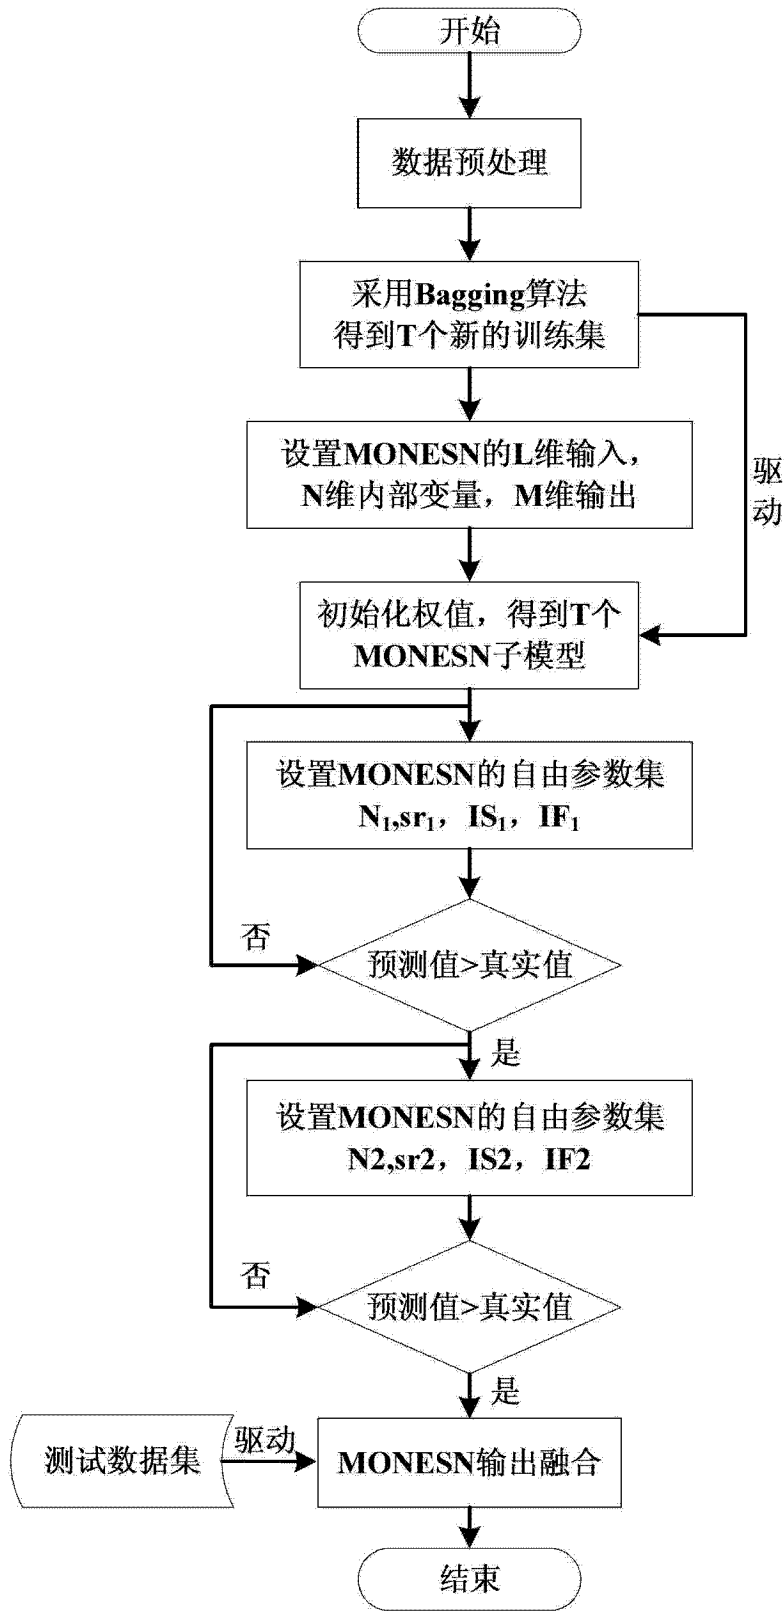


图 3




图 4




图 5




图 6




图 7




图 8