

车用锂离子动力电池剩余寿命非线性组合预测研究*

徐东辉[†]

(南昌师范学院数学与计算机科学系, 330032, 江西南昌)

摘要 针对单一预测模型难以准确预测锂电池的剩余寿命(remaining useful life, RUL)难题, 提出了非线性组合预测方法; 利用相空间重构, 对实验采集到的数据进行重构, 将重构后的数据对改进 Elman 神经网络和非线性自回归(nonlinear autoregressive with exogenous input, NARX)神经网络这 2 个单项预测模型进行训练和预测; 采用 RBF 神经网络对 2 个单项模型的预测值进行非线性组合, 获得最终的 RUL 预测值. 结果表明: 非线性组合预测方法的均方根误差比 PCA-NARX 方法提高了近 1%, 比 NARX 方法提高了近 2%, 比改进 Elman 方法提高了近 3%; 非线性组合预测方法具有较高的精度及泛化能力, 采用相空间重构技术有利于提高非线性组合方法的预测精度.

关键词 锂离子电池; 时间序列; 非线性组合; RBF; NARX; 改进 Elman; 预测

中图分类号 TM912.9

DOI: 10.12202/j.0476-0301.2021023

0 引言

锂离子动力电池具有能量密度高、无记忆效应等优势, 目前在电动汽车、航空航天等领域得到了广泛的使用. 但在使用过程中锂离子电池的 SOH、SOP 与 RUL 等性能在不断退化, 使得电动汽车在使用过程中存在巨大安全隐患, 因此, 准确预测锂离子电池的 RUL 具有重要意义^[1-2].

锂离子电池剩余寿命(remaining useful life, RUL)的研究主要集中在基于电池性能方法方面, 通常有基于物理模型、数据驱动、数据融合等方法^[3-5]. 目前国内许多学者都进行了相应的研究, 取得了较好的结果. 丁阳征等^[6]利用改进粒子群优化算法对极限学习机的输入端进行寻优, 进一步增加了对锂离子电池 RUL 预测过程中的稳定性及预测结果的可信度, 结果达到了目标要求. 庞晓琼等^[7]将主成分分析与 NARX 神经网络有效融合, 提出了 PCA-NARX 锂离子电池的 RUL 预测模型; 采用 PCA 方法去除样本参数中的冗余, 将特征提取后的样本数据作为 NARX 神经网络输入值, 进行训练和预测. 该模型的预测精度较高且适应性较强. 王一宣等^[8]采用免疫完全学习型粒子群优化算法, 优化支持向量回归机的惩罚系数和超参数, 使其达到全局最优, 并将该算法应用于锂离子电池 RUL 预测中, 预测精度较高.

已有研究仅从优化模型算法方面达到提高锂离子

动力电池 RUL 预测精度的目的, 很少有从锂离子电池系统固有的非线性特性展开研究, 并且所用到的样本数据大多是一维状态空间数据. 实际锂离子电池系统具有高度复杂的非线性特性, 其数据样本一般具有多维状态空间. 为此, 本文提出了非线性组合预测方法: 首先采用相空间重构, 对实验采集到的输入数据进行重构, 恢复锂离子动力电池系统多维非线性状态空间; 然后利用锂离子电池多维非线性状态空间时间序列, 对改进 Elman 和 NARX 神经网络分别进行训练和预测; 最后用 RBF 网络对改进 Elman 和 NARX 神经网络 2 个单项模型的输出值进行非线性组合预测, 获得最终的锂离子电池 RUL 多维非线性状态空间时间序列的预测值.

1 锂离子电池动力学系统的混沌判别

根据 Takens 定理^[9-10], 假设车用锂离子动力电池系统一维状态的空间时间序列为 $(x(i), i = 1, 2, \dots, N)$, 若存在一个嵌入维 m , 满足 $m \geq 2d + 1$ (d 为车用锂离子动力电池系统混沌吸引子的关联维数)时, 可利用时间延迟 τ 将一维状态空间时间序列重构成相空间为 R^m 的多维状态空间时间序列, 其表达式为

$$Y(i) = (x(i), x(i + \tau), x(i + 2\tau), \dots, x(i + (m - 1)\tau)), \\ i = 1, 2, \dots, M, \quad (1)$$

* 国家自然科学基金资助项目(51176014); 江西省重点研发计划项目(20192BBHL80002, 20202BBEL53019); 江西省教育厅科学技术研究项目(GJJ202609)

[†] 通信作者: 徐东辉(1978—), 男, 博士, 副教授. 研究方向: 汽车节能减排控制与新能源技术等. E-mail: 1352291506@qq.com

收稿日期: 2021-01-04

式中: $Y(i)$ 为第 i 个相点; M 为总的相点数, $M = N + (m - 1)\tau$.

则最后一个相点可表示为

$$Y(M) = (x(M), x(M + \tau), \dots, x(N)). \quad (2)$$

根据重构原理, 通过相空间重构后得到的 m 维车用锂离子动力电池系统时间序列与其原动力系统具有高度一致性.

根据小数据方法, 计算得最大 Lyapunov 指数为 0.0162, 稍大于 0. 这表明: 锂离子电池系统具有混沌动力学特性, 其样本数据时间序列应该具有多维状态空间, 可利用相空间重构恢复其固有的多维状态空间特性. 若要对实验采集到的锂离子电池系统一维数据时间序列进行相空间重构, 首先必须确定嵌入维数 m 和时间延迟 τ . 本文利用 Kim 等^[11] 所提出的 C-C 法来确定嵌入维数和时间延迟. 经计算得 $m = 8$ 、 $\tau = 3$.

2 非线性组合预测模型

2.1 改进 Elman 回归神经网络模型 Elman 模型^[12-13] 包含输入层、隐含层、输出层和承接层(图 1). 由于 Elman 神经网络具有反馈层, 所以其具有动态特性和递归作用, 目前常用于参数辨识和预测.

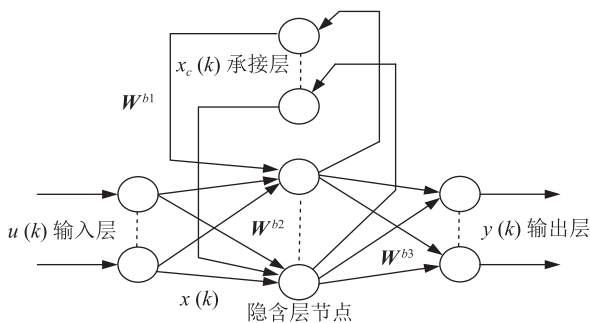


图 1 基本 Elman 回归神经网络模型结构

图 1 中 $u(k)$ 为 Elman 神经网络输入层的输入值, $x(k)$ 为隐含层的输入值, $x_c(k)$ 为承接层的输出值, $y(k)$ 为输出层的输出值.

若输入层节点为 n 个, 隐含层为 r 个, 承接层为 r 个, 输出层为 m 个, 则 W^{b1} 为 $r \times r$ 维矩阵, W^{b2} 为 $r \times n$ 维矩阵, W^{b3} 为 $m \times r$ 维矩阵. 数学表达式为

$$x(k) = f(W^{b1}x_c(k) + W^{b2}u(k)), \quad (3)$$

$$x_c(k) = x(k - 1), \quad (4)$$

$$y(k) = W^{b3}x(k). \quad (5)$$

由于基本 Elman 回归神经网络模型只能逼近一阶动态系统, 对于高阶动态系统, 则其预测精确度和

泛化能力下降. 鉴于车用锂离子动力电池系统具有高阶复杂非线性特性, 本文增加输出层节点, 输出反馈给隐含层. 对基本 Elman 回归神经网络模型进行改进, 即将输出层节点输出并反馈给隐含层, 与输入层、承接层一起作为隐含层节点的输入, 其对应的权值矩阵为 W^{b4} , 通过输出层的反馈, 进一步提高模型的预测精度和泛化能力. 图 2 为改进 Elman 回归神经网络模型结构^[14].




图 2 改进 Elman 回归神经网络模型结构

图 2 中 $\alpha \in [0, 1]$ 、 $\beta \in [0, 1]$ 为自反馈增益, W^{b1} 为改进 Elman 回归神经网络模型的承接层到隐含层的权值, W^{b2} 为输入层到隐含层的权值, W^{b3} 为隐含层到输出层的权值, W^{b4} 为输出层到隐含层的权值.

改进 Elman 回归神经网络模型数学模型如下:

$$x(k) = f(W^{b1}x_c(k) + W^{b2}u(k) + W^{b4}y_c(k)), \quad (6)$$

$$x_c(k) = \alpha x_c(k - 1) + x(k - x), \quad (7)$$

$$y_c(k) = \beta y_c(k - 1) + y(k - 1), \quad (8)$$

$$y(k) = W^{b3}x(k). \quad (9)$$

设改进 Elman 回归神经网络的第 k 步输出目标值为 $y_d(k)$, 则 Elman 的误差函数表达式可定义为

$$E(k) = (y_d(k) - y(k))^T (y_d(k) - y(k)) / 2. \quad (10)$$

在改进 Elman 模型学习算法中, 权值修正函数表达式如下:

$$\begin{cases} \Delta W_{jp}^{b4} = \gamma_4 \sum_{i=1}^m (\delta_i^0 W_{ij}^{b3}) \frac{\partial x_i(k)}{\partial W_{jp}^{b4}}, \\ \Delta W_{jp}^{b3} = \gamma_3 \delta_i^0 x_j(k), \\ \Delta W_{js}^{b2} = \gamma_2 \delta_j^h u_s(k), \\ \Delta W_{jp}^{b1} = \gamma_1 \sum_{i=1}^m (\delta_i^0 W_{ij}^{b3}) \frac{\partial x_i(k)}{\partial W_{jp}^{b1}}. \end{cases} \quad (11)$$

$$\begin{cases} \frac{\partial x_i(k)}{\partial W_{jp}^{b4}} = f_j(\cdot)y_p(k-1) + \beta \cdot \frac{\partial x_i(k-1)}{\partial W_{jp}^{b4}}, \\ \frac{\partial x_i(k)}{\partial W_{jb}^{b1}} = f_j(\cdot)x_i(k-1) + \alpha \cdot \frac{\partial x_i(k-1)}{\partial W_{jb}^{b1}}. \end{cases} \quad (12)$$

$$\begin{cases} \delta_i^0 = (y_{di}(k) - y_i(k)), \\ \delta_j^h = \sum_{i=1}^m (\delta_i^0 W_{ij}^{b3} f_j(\cdot)). \end{cases} \quad (13)$$

2.2 NARX 神经网络模型 NARX 全称为外部输入




图 3 NARX 模型结构

NARX 模型包含回归分析器和非线性估计器 2 部分^[16-17]. 非线性估计器主要由非线性模块和线性模块构成, 通过非线性模块和线性模块可以将回归分析器与模型输出之间建立起映射关系. 非线性估计器的模型为

$$y = F(u) = L^T(u-r) + d + g(Q(u-r)), \quad (15)$$

式中: y 为估计器的输出; u 为估计器的输入; $L^T(u-r)+d$ 为线性模块的输出, d 为输出偏置量; $g(Q(u-r))$ 为非线性模块的输出; r 为回归矢量的平均值; Q 为非线性子空间.

非线性估计器通常有多层神经网络、树分割网络和小波神经网络等多种形式, 本文选择小波神经网络作为 NARX 神经网络模型中的非线性估计器. 为此式(15)可表示成如下非线性函数:

$$\begin{aligned} y = F(u) = & L^T(u-r) + d + \\ & a_{s_1} f(b_{s_1}((u-r)Q - c_{s_1})) + \dots + \\ & a_{s_n} f(b_{s_n}((u-r)Q - c_{s_n})) + \\ & a_{w_1} g(b_{w_1}((u-r)Q - c_{w_1})) + \dots + \\ & a_{w_m} g(b_{w_m}((u-r)Q - c_{w_m})), \end{aligned} \quad (16)$$

式中: u 为 m 维列向量, 是非线性估计器输入值; Q 为 $m \times p$ 维投影矩阵, 是线性子模块中线性子空间; L 为 NARX 的线性模块中线性系数; d 为 NARX 模型的输出偏置; a_{s_i} 、 a_{w_i} 分别为小波神经网络的比例系数和小波系数; b_{s_i} 、 b_{w_i} 分别为小波神经网络的比例膨胀和小波膨胀; c_s 为 $1 \times q$ 维比例变换矩阵, c_w 为 $1 \times q$ 维小波变换矩阵; $f(\cdot)$ 和 $g(\cdot)$ 均为小波神经网络的径向函数, 其函数表达式为

非线性自回归神经网络, 是一种动态的前馈神经网络, 属于动态神经网络的范畴, 具有较强的非线性映射及泛化能力, 很适合用于非线性领域的时间序列预测方面. 图 3 为 NARX 模型结构^[15], 其数学模型表达式为

$$\begin{aligned} y(t) = & f(y(t-1), \dots, y(t-n_a), \\ & u(t-n_k), \dots, u(t-n_k-n_b+1)), \end{aligned} \quad (14)$$

式中 $u(t)$ 、 $y(t)$ 分别为 t 时刻的系统输入和输出, $f(\cdot)$ 为非线性函数, n_a 、 n_b 、 n_k 分别为 NARX 模型的输出阶次、输入阶次和输出延时量.

$$\begin{cases} f(u) = e^{-0.5uu^T}, \\ g(u) = (\dim(u) - uu^T)e^{-0.5uu^T}. \end{cases} \quad (17)$$

则式(16)可表示为

$$\begin{aligned} F(u) = & L^T(u-r) + d + \\ & \underbrace{\sum_{i=1}^{n_s} a_{s_i} f(b_{s_i}((u-r)Q - c_{s_i})) + \sum_{i=1}^{n_w} a_{w_i} g(b_{w_i}((u-r)Q - c_{w_i}))}_{g(Q(u-r))}, \end{aligned} \quad (18)$$

式中 $L^T(u-r)+d$ 为 NARX 模型中线性模块的输出, $g(Q(u-r))$ 为 NARX 模型中非线性模块的输出.

2.3 基于 RBF 神经网络的非线性组合预测模型 非线性组合预测方法最早由 BATES 等^[17] 提出, 可更加真实、准确地反映非线性系统的固有特性. 若目标函数有较好的解析性时, 该方法的预测精度会更高. 它在最终预测结果与单个预测模型之间形成一个非线性映射关系, 其组合函数为

$$\hat{y} = \phi(f_1, f_2, \dots, f_m), \quad (19)$$

式中 \hat{y} 是非线性组合预测结果, ϕ 是非线性映射函数.

本研究选择改进 Elman 与 NARX 神经网络 2 种单项模型, 对锂离子电池系统多维非线性状态空间时间序列进行预测, 得到表征电池性能退化的特征量容量, 再用 RBF 神经网络模型对 2 种单项预测值进行非线性组合预测, 得到最终的 RUL 预测值.

RBF 是一种前馈式神经网络^[18]. 由于本文最终目标是得到锂离子电池的 RUL 预测值, 也就是单一输出值, 因此选择多输入单输出模型结构, 图 4 为 RBF 网络结构. 图中: $x_{i,j}$ 为输入变量, $i = 1, 2, \dots, M, j = \max_{1 \leq i \leq M} (m_i - 1); \tau_i + 1, \dots, N, m = m_1 + m_2 + \dots + m_M; w = (w_1, w_2, \dots, w_M)^T$




图 4 多输入单输出 RBF 神经网络

为该网络输出层的权值向量; $x_{1,n+1}$ 为输出层的最终辨识值。

$\phi(x)$ 为高斯函数, 其数学表达式为

$$\phi(\|V_n - C_j\|) = \exp\left\{-\frac{\|V_n - C_j\|^2}{2\sigma_j^2}\right\}, \quad (20)$$

式中 V_n 为训练样本中第 n 个输入样本, C_j 、 σ_j 分别为高斯函数的中心值和宽度。

RBF 神经网络的输出为

$$x_{1,n+1} = \sum_{j=1}^k w_j \phi(\|V_n - C_j\|), \quad (21)$$

式中 k 为隐含层节点数。

网络输出误差定义为

$$e_j = x_{1,j+1} - \sum_{i=1}^k w_i \phi(\|x_j - c_i\|), \quad (22)$$

式中 $x_{1,j+1}$ 为实际负荷值。

为解决 RBF 神经网络收敛速度慢的缺陷性, 同样利用 Logistic 映射混沌模型对基函数中心 C_j 、宽度 σ_j 和输出层权值 w_j 取混沌变量, 使其快速达到全局最优, 避免陷入局部最优。

假设锂离子电池容量的实测值为 $y_t, t = 1, 2, \dots, z$; x_{it} 为 Elman 与 NARX 这 2 个单一预测模型在 t 时刻的容量预测值, $i = 1, 2, t = 1, 2, \dots, l$ 。把 2 个单一预测模型所参加组合的预测结果 $X_t = (x_{1t}, x_{2t}), t = 1, 2, \dots, l$, 与相应时刻的实际容量值 $y_t, t = 1, 2, \dots, l$, 构成 RBF 神经网络的训练样本集和测试集 $z_t = (X_t, y_t)$ 、 $X_t \in R^m, t = 1, 2, \dots, l$ 。文中利用 RBF 神经网络预测模型, 采用一步预测法对时间序列 $z_t = (X_t, y_t)$ 、 $X_t \in R^m, t = 1, 2, \dots, l$, 进行预测, 具体实施步骤如下:

1) 利用相空间重构技术, 构造 k 个点的 m 维训练数据 ($m < k < N, m \geq 2d + 1, d$ 为混沌系统维数), 输入分别是

$$Z_1 = (z_1, z_2, \dots, z_m), Z_2 = (z_2, z_3, \dots, z_{m+1}), \dots,$$

$$Z_k = (z_k, z_{k+1}, \dots, z_{k+m}),$$

对应的理想输出是

$$Y_1 = z_{m+1}, Y_2 = z_{m+2}, \dots, Y_k = z_{k+m+1}.$$

2) 将各个输入按顺序输入网络, 得到相应的理想输出分别是 Y_1, Y_2, \dots, Y_n , 经训练后即可得到 RBF 网络模型

$$Y_i = f(Z_i), \quad (23)$$

式中 $Y_i = z_{i+m+1}, 1 \leq i \leq k, Z_i = (z_i, z_{i+1}, \dots, z_{i+m})$ 。

3) 由一步辨识法, 有

$$Y_{k+1} = \hat{z}_{k+m+2} = f(z_{k+1}, z_{k+2}, \dots, z_{k+m+1}), \quad (24)$$

即 $Z_{k+2} = F(Z_{k+1}), Z_{k+3} = (z_{k+2}, z_{k+3}, \dots, z_{k+m+1}, \hat{z}_{k+m+2})$ 。同理,

$$\hat{z}_{k+m+3} = f(z_{k+2}, z_{k+3}, \dots, z_{k+m+1}, \hat{z}_{k+m+2}). \quad (25)$$

依此类推, 则可得车用锂离子电池 RUL 状态空间时间序列的最终预测结果。

3 非线性组合估测模型实验仿真

3.1 实验数据采集 实验平台由 Arbin-BT2000 测试仪、GD-JS41 型恒温箱、3 个额定容量为 $2 \text{ A} \cdot \text{h}$ 的 18650 型号的单体锂离子电池和上位 PC 机构成。实验过程中, 在常温下进行充电、放电和电阻测量 3 种不同的操作。

恒流恒压充电: 以 1 C 恒流充电至 4.2 V , 使 $I \leq 20 \text{ mA}$, 然后保持 $(4.2 \pm 0.05) \text{ V}$ 不变, 使充电电流逐渐减小, 当 $I \leq 36 \text{ mA}$ 时, 恒流恒压充电结束。

恒流放电: 以恒定电流放电至电池电压 2.5 V 截止。如此进行循环充放电, 并计算每个周期的实时容量。

以上步骤记为 1 次循环过程, 每次循环过程以 1 Hz 的频率采集记录电池终端电压、电流、温度、负荷电压, 电流, 以及数据采集时间等实验数据, 电池循环 200 次后结束实验。采用电化学阻抗谱法测量电池阻抗, 其频率扫描范围为 $0.1 \sim 5.0 \text{ Hz}$, 电池静置时间为 30 min 。

为构建与容量成强相关的退化特征, 本文选择 Spearman 秩相关系数来度量间接参数与容量之间的相关性。通过计算, 选出等压放电时间、恒压充电过程充电持续时间、放电功率、电池阻抗、充电过程电池温度达到峰值所用时间等 5 组与实际容量相关性高且具有代表性的间接参数, 作为非线性组合预测模型的训练与预测数据, 并对 5 组间接参数进行相空间重构, 使一维时间序列恢复锂离子电池原有的非线性状态空间, 共获得 168×5 组数据。

3.2 预测模型训练与预测 从 NASA PCoE 所公开的数据集中提取 B5、B6 和 B7 电池容量退化数据各 168

组. 将 B5 电池前 80×1 组数据与实验获得的前 80×5 组数据, 组成 80×6 组, 作为改进 Elman 神经网络预测模型与 NARX 神经网络预测模型的训练集; 将 B5 电池后 88×1 组数据与实验获得的后 88×5 组数据组成 88×6 组数据, 作为改进 Elman 与 NARX 模型的测试集; 将改进 Elman 模型与 NARX 模型的输出值作为 RBF 模型的输入值, 进行非线性组合预测, 获得最终 B5 电池的 RUL 值(B5 电池的失效阈值设为 1.382 A·h).

将 B6 和 B7 电池的前 60×1 组数据, 与实验获得的前 60×5 组数据, 组成 60×6 组数据, 作为改进 Elman 神经网络预测模型与 NARX 神经网络预测模型的训练集; 将 B6 和 B7 电池的后 108×1 组数据, 与实验获得的后 108×5 组数据, 组成 108×6 组数据, 作为改进 Elman 神经网络预测模型与 NARX 神经网络预测模型的测试集; 将改进 Elman 模型与 NARX 模型的输出值, 作为 RBF 模型的输入值进行非线性组合预测, 获得最终 B6 和 B7 电池的 RUL 值(B6 电池的失效阈值设为 1.400 A·h, B7 电池的失效阈值设为 1.463 A·h). 图 5-a、b、c 分别为 B5、B6 和 B7 各模型的容量预测结果.




图 5 B5、B6、B7 电池容量预测结果

3.3 误差分析与比较 本文采用均方根误差 (E_{RMS}) 与平均绝对误差 (E_{MA}) 作为定量评价非线性组合预测模型准确性的性能指标. 数学表达式为

$$E_{RMS} = \left(\sum_{i=1}^N (\hat{S}_i - S_i)^2 / N \right)^{1/2}, \quad (26)$$

$$E_{MA} = \frac{1}{N} \sum_{i=1}^N |\hat{S}_i - S_i| / S_i, \quad (27)$$

式中 S_i 为实测值, \hat{S}_i 为预测值, N 为数据个数.

表 1 为 B5、B6 与 B7 各模型的 RUL 预测结果对比. 通过表 1 与图 5 的误差分析与比较, 可得非线性组合预测模型在精度及稳定性等方面优于改进 Elman 与 NARX 神经网络, 具有较好的收敛速度和非线性预测能力. 该预测模型适合于对锂离子电池 RUL 状态空间时间序列的预测.

表 1 B5、B6 及 B7 各模型 RUL 预测结果对比

电池类型	预测模型	训练周期/次	R/%	M/%
B5	改进Elman	80	4.13	4.52
	NARX	80	3.26	3.68
	非线性组合	80	1.52	1.25
B6	改进Elman	60	4.18	4.18
	NARX	60	3.34	3.13
	非线性组合	60	1.37	1.14
B7	改进Elman	60	4.29	4.25
	NARX	60	3.18	3.87
	非线性组合	60	1.42	1.18

4 结论

1) 对基本的 Elman 回归神经网络模型进行了改进, 提高了 Elman 回归神经网络模型的预测精度和泛化能力.

2) 利用改进 Elman、NARX 神经网络与 RBF 神经网络, 建立了非线性组合预测模型, 并将 RUL 的一维时间序列重构成了多维状态空间时间序列, 恢复了锂离子电池系统固有的多维非线性状态空间; 利用 Logistic 映射混沌模型对 RBF 神经网络的基函数中心、宽度与输出层权值取混沌变量, 使其快速达到全局最优, 避免了陷入局部最优.

3) 对非线性组合预测模型进行了试验仿真. 本文提出的非线性组合预测方法比改进 Elman 神经网络的均方根误差提高了近 3%, 比 NARX 神经网络的均方根误差提高了近 2%, 比文献 [7] 提出的 PCA-NARX 算法均方根误差提高了近 1%, 表明非线性组合预测方法具有较高的精度及泛化能力. 采用重构技术有利于提高锂离子电池 RUL 状态空间时间序列的预测精度.

致谢 本研究工作得到了长沙理工大学李岳林教授的帮助, 在此表示衷心感谢!

5 参考文献

- [1] CANO Z P, BANHAM D, YE S, et al. Batteries and fuel cells for emerging electric vehicle markets[J]. *Nature Energy*, 2018, 3(4): 279
- [2] YANG J F, XIA B, HUANG W X, et al. Online state-of-health estimation for Lithium-ion batteries using constant-voltage charging current analysis[J]. *Applied Energy*, 2018, 212: 1589
- [3] SHEN P, OUYANG M, LU L, et al. The coestimation of state of charge, state of health and state of function for Lithium-ion batteries in electric vehicles[J]. *IEEE Transactions on Vehicular Technology*, 2017, 67(1): 92
- [4] 王常虹, 董汉城, 凌明祥, 等. 车用锂离子电池剩余使用寿命预测方法[J]. *汽车工程*, 2015, 37(4): 476
- [5] WASSILIADIS N, ADERMANN J, FRERICKS A, et al. Revisiting the dual extended Kalman filter for battery state-of-charge and state-of-health estimation: a use-case life cycle analysis[J]. *Journal of Energy Storage*, 2018, 19: 73
- [6] 丁阳征, 贾建芳. 改进PSO优化ELM预测锂离子电池剩余寿命[J]. *电子测量与仪器学报*, 2019, 33(2): 72
- [7] 庞晓琼, 王竹晴, 曾建潮, 等. 基于PCA-NARX的锂离子电池剩余使用寿命预测[J]. *北京理工大学学报*, 2019, 39(4): 406
- [8] 王一宣, 李泽滔. 基于改进支持向量回归机的锂离子电池剩余寿命预测[J]. *汽车技术*, 2019, 2: 28
- [9] PACKARD N H, CRUTCHFIELD J P, FARMER J D, et al. Geometry from a time series[J]. *Physics Review Letters*, 1980: 712
- [10] TAKENS F. Detecting strange attractors in turbulence[C]//Lecture Notes in Mathematics, 898. Bedi: Springer, 1981: 416
- [11] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamie, delay times, and embedding windows[J]. *Physica D*, 1999, 127: 48
- [12] VAPNIK V. The nature of statistical learning theory[M]. 2th ed. New York: Springer-Verlag, 1999
- [13] TRAFALIS T B, INCE H. Support vector machine for regression and applications to financial forecasting[C/OL]. [2020-12-15]. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.98.8436&rep=rep1&type=pdf>
- [14] SU G, GONG W. Maximum power point tracing of photovoltaic cells with OIF-Elman network[C]. Beijing: Control Conference (CCC), 2010, 29: 4880
- [15] BEYHAN S, ALCI M. Fuzzy functions based ARX model and new fuzzy basis function models for nonlinear system identification[J]. *Applied Soft Computing*, 2010, 10(2): 439
- [16] 李应求, 安勃, 李恒通. 基于NARX及混沌支持向量机的短期风速预测[J]. *电力系统保护与控制*, 2019, 47(23): 65
- [17] BATES J M, GRANGER C W J. The combination of forecasts [J]. *Journal of the Operations Research Quarterly*, 1969, 20(4): 451
- [18] 乔良, 宋小欣, 谢延敏, 等. 基于PSO-RBF代理模型的板料成形本构参数反求优化研究[J]. *中国机械工程*, 2014, 25(19): 2680

Nonlinear combination prediction of remaining useful life of automotive Lithium-ion batteries

XU Donghui[†]

(Department of Mathematics and Computer Science, Nanchang Normal University, 330032, Nanchang, Jiangxi, China)

Abstract Due to difficulty of accurately predicting residual life of Lithium batteries with a single prediction model, a nonlinear combination prediction method is proposed in this work. Phase space reconstruction was used to reconstruct data collected from experiments. Reconstructed data were trained and predicted on two single prediction models, improved Elman neural network and nonlinear autoregression neural network. RBF neural network was used to combine predicted values of the two single prediction models, final RUL predicted value was then obtained. The proposed nonlinear combination forecast method of mean square error was found to be nearly 1% higher than PCA-NARX, nearly 2% higher than NARX, nearly 3% higher than improved Elman. Nonlinear combination forecasting method had higher precision and generalization ability. It is concluded that phase space reconstruction technology is helpful to improve prediction precision of nonlinear combination method.

Keywords Lithium-ion battery; chaotic sequence; nonlinear combination; RBF; NARX; improved Elman; predict

【责任编辑: 陆有忠】