

控制与决策

Control and Decision

基于自适应混合优化的电力数据预测方法

曾朝晖, 赵会勇, 罗恩韬, 张英豪, 杨阳, 严一泰

引用本文:

曾朝晖,赵会勇,罗恩韬,张英豪,杨阳,严一泰. 基于自适应混合优化的电力数据预测方法[J]. *控制与决策*, 2023, 38(12): 3490–3498.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.2224>

您可能感兴趣的其他文章

Articles you may be interested in

[基于小波变换与差分变异BSO–BP算法的大坝变形预测](#)

Dam deformation prediction based on wavelet transform and differential mutation BSO–BP algorithm

控制与决策. 2021, 36(7): 1611–1618 <https://doi.org/10.13195/j.kzyjc.2019.1431>

[基于FWADE–ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE–ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于FWADE–ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE–ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于卷积长短时记忆神经网络的城市轨道交通短时客流预测](#)

Metro short-term traffic flow prediction with ConvLSTM

控制与决策. 2021, 36(11): 2760–2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

[基于深度时序特征迁移的轴承剩余寿命预测方法](#)

Remaining useful life prediction of bearing based on deep temporal feature transfer

控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

基于自适应混合优化的电力数据预测方法

曾朝晖^{1†}, 赵会勇¹, 罗恩韬², 张英豪¹, 杨阳¹, 严一泰¹

(1. 湘潭大学 智能计算与信息处理教育部重点实验室, 湖南 湘潭 411105;

2. 湖南科技学院 信息工程学院, 湖南 永州 425099)

摘要: 电力数据易受气候、季节、节假日等因素影响, 出现不同波动特征. 针对不同特征电力数据预测精度不高、预测方法泛化能力弱等问题, 提出基于自适应混合优化的电力数据预测方法. 通过使用小波变换和平稳性分析, 将电力数据自适应地分解为包含趋势、季节和周期信息的非平稳序列和多个平稳序列; 使用状态转移算法分别优化长短时记忆深度学习网络和自回归移动平均模型, 对非平稳序列和平稳序列分别拟合、预测; 对预测的各序列进行重构, 得到最终预测结果. 在电力系统数据上进行多步预测, 对比实验表明: 与其他方法相比, 所提方法不仅具有更高的预测精度, 还具有较强的泛化能力.

关键词: 电力数据预测; 长短期记忆深度学习网络; 自回归移动平均模型; 小波分解; 状态转移算法

中图分类号: TP391.9

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.2224

引用格式: 曾朝晖, 赵会勇, 罗恩韬, 等. 基于自适应混合优化的电力数据预测方法[J]. 控制与决策, 2023, 38(12): 3490-3498.

Power data forecasting method based on adaptive hybrid optimization

ZENG Zhao-hui^{1†}, ZHAO Hui-yong¹, LUO En-tao², ZHANG Ying-hao¹, YANG Yang¹, YAN Yi-tai¹

(1. Key Laboratory of Intelligent Computing and Information Processing of Ministry of Education, Xiangtan University, Xiangtan 411105, Cihna; 2. School of Information Engineering, Hunan University of Science and Technology, Yongzhou, 425099, China)

Abstract: Power data are easily affected by climate, seasons, holidays and other factors, with different fluctuation characteristics. Aiming at the problems of low prediction accuracy of power data with different characteristics and weak generalization ability of prediction methods, a power data prediction method based on adaptive hybrid optimization is proposed. By using wavelet transform and stability analysis, the power data is adaptively decomposed into non-stationary series and multiple stationary series containing trend, season and periodic information. The state transition algorithm is used to optimize the long and short term memory deep learning network and autoregressive moving average model, respectively, to fit and predict the non-stationary and stationary series. Finally, the predicted sequences are reconstructed to obtain the final prediction results. Compared with other methods, the proposed method not only has higher prediction accuracy, but also has strong generalization ability.

Keywords: power data forecast; long and short term memory deep learning network; autoregressive moving average model; wavelet decomposition; state transition algorithm

0 引言

由于发电、输电、用电过程同步进行, 存储电能代价较高, 需制定合理的电力调度方案, 以保证电力系统高效稳定运行. 因此, 发电量和电力负荷预测的精确性和稳定性不仅能显著提高电力系统运行的经济效益, 还有助于实现智能电网的自主控制与决策.

电力系统数据易受气候、环境、节假日等众多

因素影响, 各影响因素关系复杂, 难以建立精确的数学模型. 发电量和电力负荷等数据包含趋势、季节和周期等非平稳因素, 导致预测难度大. 现有电力数据预测方法主要有基于统计的方法、基于机器学习的方法和混合方法. 基于统计的预测方法有自回归差分移动平均 (ARIMA)^[1] 方法、自回归移动平均 (ARMA)^[2-3] 等方法. 文献[2]对原始太阳能发电量采

收稿日期: 2021-12-23; 录用日期: 2022-07-06.

基金项目: 湖南省教育厅科学研究重点项目 (21A0069); 国家自然科学基金面上项目 (62172159); 湖南省自然科学基金面上项目 (2021JJ30294).

责任编辑: 孙秋野.

[†]通讯作者. E-mail: zzh@xtu.edu.cn.

用ARMA模型建模预测,根据BIC准则选择ARMA参数.基于机器学习的非线性预测方法分为统计学习方法和神经网络方法.统计学习方法有支持向量机(SVM)^[4]、极限学习机(ELM)^[5]等,在低维数据预测中可取得良好效果,但对于复杂的电力数据,存在建模和模型训练困难、模型泛化能力弱等问题,使得预测精度受到限制.神经网络方法有浅层神经网络BP(back propagation)^[6]、深度学习网络受限玻尔曼机(RBM)^[7]、循环神经网络(RNN)^[8]、深度残差网络(DRN)^[9]、长短期记忆网络(LSTM)^[10-12]等.如文献[9]使用改进DRN深度学习网络进行不同季节的短期电力预测,预测精度均优于非神经网络SVM、ARIMA等模型;文献[11]使用LSTM网络解决了两种类型的电力预测问题,一是大范围区域的未来24h的电力预测,二是小区域的未来1h的电力预测.首先使用波兰全国电力系统的数据库,对波兰全国未来一天24h的电力负荷做预测,其次是用波兰某个区域的电力系统数据,对某个区域的未来1h的电力负荷做预测.对于全国的电力数据,整体的波动情况较为稳定,而区域的电力数据通常表现负荷需求变化较大,这两种电力预测的难度不一,有效验证了LSTM网络对不同电力预测问题的可行性.基于分解的混合方法将电力数据进行分解再预测,以达到提高预测精度的目的,其中变分模态分解^[13](variational mode decomposition, VMD)和小波分解^[14](wavelet decomposition, WD)是常用的分解方法.文献[13]使用VMD对电力负荷序列进行多层分解得到多个本征模态函数(intrinsic mode functions, IMFs),然后将单独的IMF作为ELM神经网络的输入进行训练预测,最后聚合所有的IMF分量的预测得到预测结果,通过实验对比可知,经过分解的VMD-ELM与单一的ELM相比,各项误差指标均有下降;文献[14]在预测超短期风电功率时,首先运用小波将数据进行固定的3层小波分解,将分解后的多个子序列放入最小资源分配网络(MRAN)的神经网络中,对未来4h的风电功率进行预测,最后用小波重构经过神经网络预测的序列得到结果.通过实验结果发现,运用小波对数据进行分解和重构,较大地提高了神经网络的预测精度.

基于神经网络的预测方法在训练过程中能自动地从数据中学习隐含规律,对非平稳电力数据具有较强的拟合预测能力,但仍然存在训练难度大、参数设置繁琐等问题,对波动频繁的电力数据难以在训练、参数设置、预测精度和泛化能力等方面同时达到最优.近些年来,对于神经网络参数优化^[15-17],很多学者提出了很多方法,如文献[16]用粒子群算法对

LSTM网络神经元数量、学习率等参数进行寻优.

综上所述,对于平稳序列的电力数据,采用统计学习方法的ARMA模型可以得到较好的预测效果.对于ARMA模型阶数,传统的BIC准则虽然可以对其阶数进行限定,但存在选择的阶数对模型预测不稳定等问题.神经网络较强的非线性拟合能力对非平稳的电力数据有较为理想的预测效果.有关神经网络参数选择问题,经典粒子群算法可以对神经网络的参数进行寻优,可以较好地避免凭经验设置参数的消极影响.但经典粒子群算法在问题求解过程中易陷入局部最优解,难以得到精确的最优解.若加速系数、最大速度等参数过大,则粒子群可能错过最优解,算法不收敛,由于所有的粒子都朝着最优解的方向寻优,所有粒子趋向同一化,失去了多样性,造成后期粒子收敛速度变慢,达到解的精度也不高.基于分解的混合方法可以提高预测精度,但是VMD分解效果受多个关键参数影响,如模态数、模态带宽和收敛容限(影响重构精度),这些关键参数均没有通用方法确定,需要根据时间序列自身特点适当选定.

本文提出一种混合优化的电力预测方法,该方法利用小波变换将复杂的电力系统数据分解,其优点在于:可将电力数据自适应地分解成包含趋势、季节和周期信息的非平稳序列和多个平稳序列,同时还可以完全重构原始序列.因此,小波变换非常适合用于时间序列的分析与预测.对于分解层数的选取,文献[14]采用固定3层小波分解.本文则采取自适应的小波变换方法,分解层数由平稳性检测^[18]结果而定,对于不同数据集的分解层数不同.对通过平稳性检测的子序列使用ARMA模型建模,对非平稳子序列使用LSTM网络.鉴于上述ARMA和LSTM参数选取算法存在的不足,本文引用状态转移算法^[19](state transition algorithm, STA)分别对LSTM参数和ARMA阶数进行优化,进一步提高模型的预测精度.状态转移算法是一种基于状态空间转移思想的智能优化算法,对于单目标优化问题是具有快速性、可控性、全局性和保证最优的智能优化算法.该算法与粒子群等多种经典的优化算法相比,可以更快地找到优化问题的最优解.综合ARMA和LSTM预测值,得到最终预测结果.

1 相关理论

1.1 小波变换

小波变换是基于小波分解、重构构成.该方法利用低通滤波器和高通滤波器将信号分解为包含趋势项信息 C_n 和细节项信息 D_n, D_{n-1}, \dots, D_1 的不同分量.在本文小波变换中,将电力数据序列视为信号,为

充分挖掘信号的细节,对序列信号进行小波分解.假设待分解的电力数据序列为 \tilde{C}_0 ,被分解为 n 层, n 由平稳检测检测结果而定,其表达式为

$$f(\tilde{C}_0) = C_n + D_n + D_{n-1} + \dots + D_1. \quad (1)$$

经过重构可以将不同的分量构成新的序列,与原始序列对比,新的序列更能准确表示电力负荷序列的潜在信息,进而提升模型的预测精度.小波分解为

$$Wf(a, v) = \langle f(t), \psi_{a,v}(t) \rangle = |a|^{-1/2} \int_{\mathbb{R}} f(t) \psi\left(\frac{t-v}{a}\right) dt. \quad (2)$$

其中: a 和 v 分别为伸缩因子和平移因子, $f(t)$ 为分析信号函数, $\psi_{a,v}(t)$ 为基本小波.重构公式为分解公式的逆变换.

1.2 状态转移算法

状态转移算法是一种基于状态转移空间思想的新型智能优化算法,它的基本思想是将优化问题的一个解看作是一个状态,解的产生和更新视为状态转移的过程,状态转移过程的具体形式如下:

$$x_{k+1} = A_k x_k + B_k u_k, y_{k+1} = f(x_{k+1}). \quad (3)$$

其中: x_k 为当前状态,代表优化问题的一个解; A_k 和 B_k 为状态转移矩阵; u_k 为当前状态和历史状态相关的函数; f 为适应度函数.对于求解优化问题,分别定义了旋转、平移、伸缩、轴向4种不同状态的变换,即

$$x_{k+1} = x_k + \alpha \frac{1}{n \|x_k\|_2} R_r x_k, \quad (4)$$

$$x_{k+1} = x_k + \beta R_t \frac{x_k - x_{k-1}}{n \|x_k - x_{k-1}\|_2}, \quad (5)$$

$$x_{k+1} = x_k + \gamma R_e x_k, \quad (6)$$

$$x_{k+1} = x_k + \delta R_a x_k. \quad (7)$$

其中: α 、 β 、 γ 、 δ 分别为旋转、平移、伸缩、轴向因子, $R_r \in \mathbf{R}^{n \times n}$ 为一个元素在 $[-1, 1]$ 范围内均匀分布的随机矩阵, $\|\cdot\|$ 为向量2的范数, $R_a \in \mathbf{R}^{n \times n}$ 为服从高斯分布的稀疏随机对角矩阵, $R_t \in \mathbf{R}^{n \times n}$ 为元素在 $[0, 1]$ 范围内均匀分布的随机变量, $R_e \in \mathbf{R}^{n \times n}$ 为服从高斯分布的随机对角矩阵.

1.3 LSTM网络

LSTM是一种改进的RNN,LSTM缓解了循环神经网络RNN面临的短内存这一巨大问题.LSTM单元包括3个门:遗忘门、输入门和输出门.

step 1: 遗忘门决定保留还是遗忘前一个时间戳的信息.

$$f_t = \text{sigmoid}(w_f \cdot x_t + w_f \cdot h_{t-1} + b_f). \quad (8)$$

step 2: 输入门确定什么样的新信息被存放在细胞状态中.这里包含两个部分,首先sigmoid层决定什么值更新,其次一个tanh层创建一个新的候选值向量

加入到细胞状态中.

$$\hat{i}_t = \text{sigmoid}(w_i \cdot x_t + w_i \cdot h_{t-1} + b_i), \quad (9)$$

$$\tilde{c}_t = \text{tanh}(w_c \cdot x_t + w_c \cdot h_{t-1} + b_c). \quad (10)$$

step 3: 更新细胞状态,将旧状态与输入门相乘,接着加上丢弃掉信息后所留下的信息.

$$c_t = f_t \cdot c_{t-1} + \hat{i}_t \cdot \tilde{c}. \quad (11)$$

step 4: 输出门的输出将基于细胞状态,其过程也分为两部分:sigmoid层确定细胞状态的哪个部分将输出;细胞状态通过tanh进行处理并将它和sigmoid门的输出相乘,最后输出确定输出的部分.

$$o_t = \text{sigmoid}(w_o \cdot x_t + w_o \cdot h_{t-1} + b_o), \quad (12)$$

$$h_t = o_t \cdot \text{tanh}(c_t). \quad (13)$$

其中: w 、 b 对应各门的权重矩阵和偏置, h_t 、 h_{t-1} 分别为上个时间和当前隐藏层的输出.

1.4 ARMA

ARMA多用于时间序列的数据建模,若给定一个时间序列 $\{x_t\}$,对于某一时刻 t 和前 p 个时刻:

自回归(autoregressive, AR)模型可表示为

$$\text{AR}(p) : x_t = \sum_{i=1}^p \varphi_i x_{t-i} + \varepsilon_t. \quad (14)$$

移动平均(moving average, MA)模型是对各个时期白噪声进行线性求和,即

$$\text{MA}(q) : x_t = \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}, \quad (15)$$

其中 $\{\varepsilon_t\}$ 为白噪声.

ARMA可被视作AR与MA的线性组合,即

$$\text{ARMA}(p, q) : x_t = \sum_{i=1}^p \varphi_i x_{t-i} + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}. \quad (16)$$

1.5 ADF平稳性检测

ADF检验是在DF检验上扩展而来的,假设对于 p 阶自回归模型, $\{\varepsilon_t\}$ 为白噪声的随机误差项,且有

$$x_t = \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t, \quad (17)$$

它的特征方程为

$$\lambda^p - \phi_1 \lambda^{p-1} - \dots - \phi_p = 0. \quad (18)$$

如果该方程特征根都在单位圆内,即 $|\lambda_i| < 1$, $i = 1, 2, \dots, p$,则序列 $\{x_t\}$ 平稳.如果有一个特征存在,不妨设 $\lambda_1 = 1$,则该序列 $\{x_t\}$ 非平稳,且自回归系数恰好等于1,即

$$\lambda^p - \phi_1 \lambda^{p-1} - \dots - \phi_p = 0 \stackrel{\lambda=1}{\Rightarrow} 1 - \phi_1 - \dots - \phi_p = 0 \Rightarrow \phi_1 + \phi_2 + \dots + \phi_p = 1. \quad (19)$$

故可以通过可检验自回归系数之和是否等于1(即所有的特征根小于1)来检验序列的平稳性.对于ADF阶次 p 的确定,一般采用信息熵准则,记为FPE,其数学表达式为

$$FPE(p) = \frac{N+p}{N-p} \hat{\sigma}_a^2 \quad (20)$$

其中: N 为样本的个数, $\hat{\sigma}_a^2$ 为模型残差. 当 FPE 最小时, p 为模型的阶数.

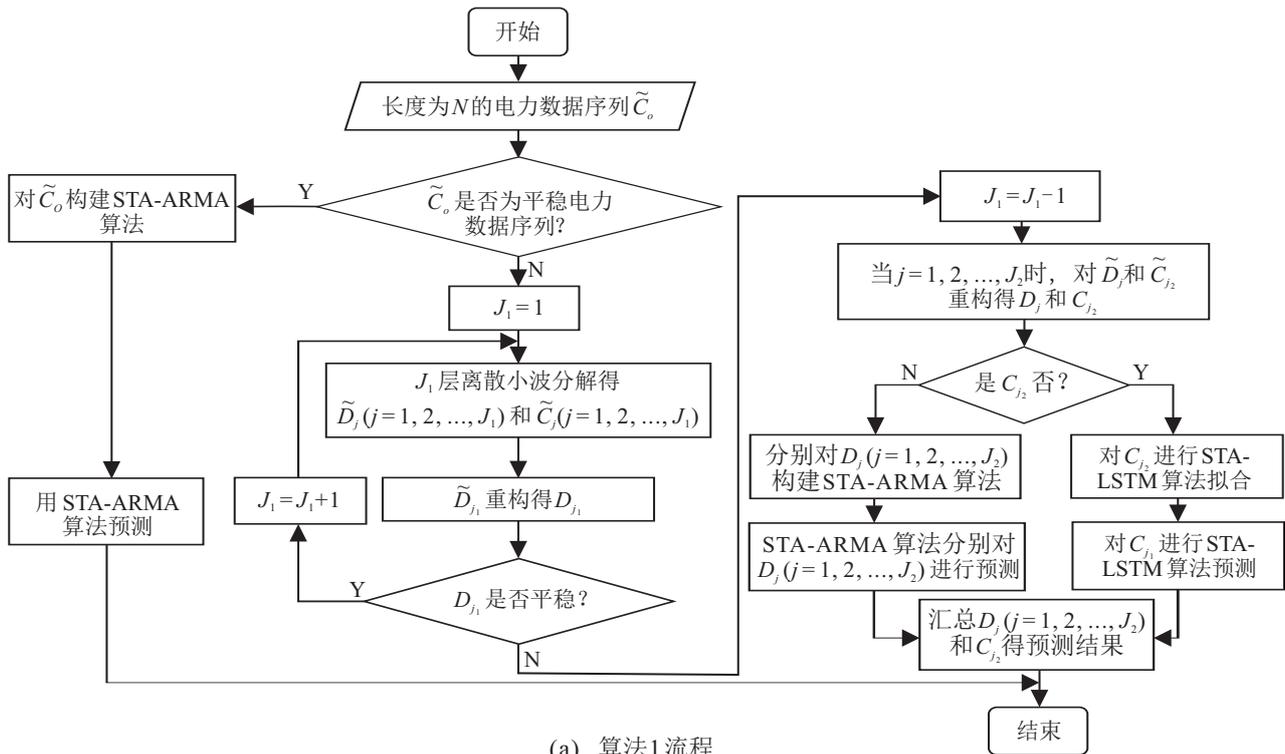
2 混合算法设计

2.1 算法1 (WD-STA-ARMA-LSTM)

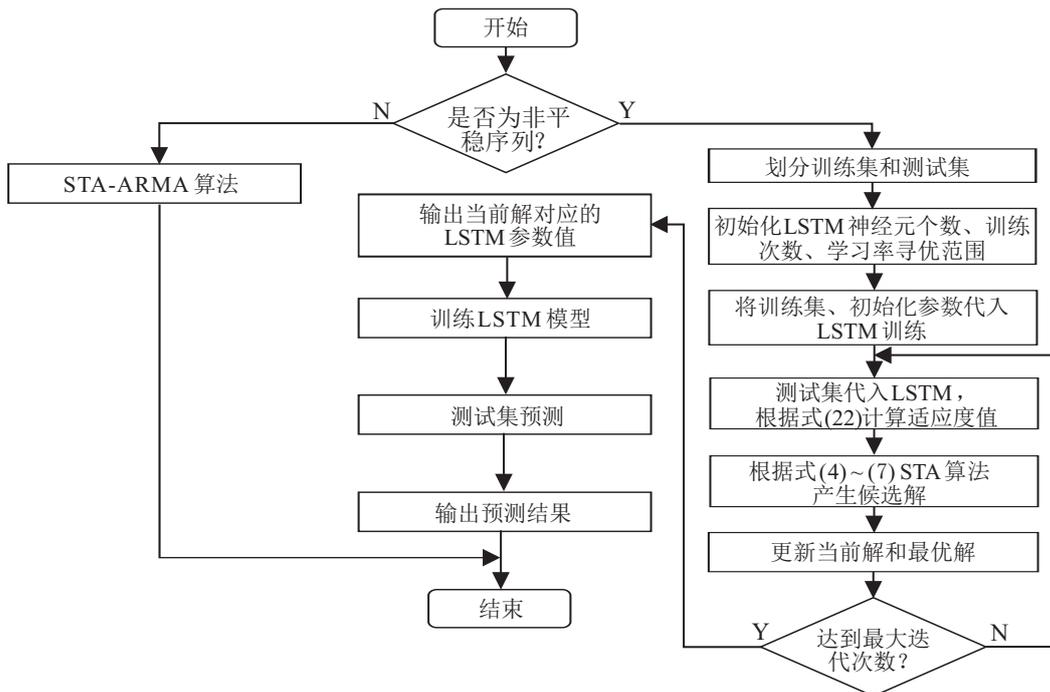
电力系统数据包含趋势项、不规则项等众多不平稳因素, 引入小波变换对电力系统数据多层分解,

小波变换级数依据平稳性检测结果而定, 对细节子序列依次检测, 直到第1个未通过平稳性检测的细节子序列, 记该层为小波变换的级数. 对通过平稳性检测的细节子序列采取 ARMA 模型预测, 对非平稳的趋势子序列构建 LSTM 网络进行预测, 利用 STA 算法分别对 ARMA 阶数和 LSTM 参数进行优化. 最后综合两个算法的预测得到最终结果.

算法1流程如图1(a)所示.



(a) 算法1流程



(b) 算法2流程

图1 算法流程

2.2 算法2 (STA-LSTM优化算法)

神经网络中神经元数量、学习率、网络训练次数等参数的设置直接关系模型性能. 神经元数量太多会使得训练效率低下甚至训练效果不好, 过少的神经元数量又会导致神经网络学习能力不足. 过大的学习率虽然使得模型损失函数更容易达到局部最优或全局最优, 但后期损失函数的值会在最小值周围波动较大, 难以达到最优; 过小的学习率虽然可以使得模型损失较容易达到最优值, 但需要模型迭代次数过多, 损失函数变化缓慢. 故需要选取合适的学习率使得模型较好地训练. 网络的迭代次数也是一个关键的参数, 网络训练次数太少会使得网络模型欠拟合, 预测能力不佳, 过多的训练次数也会导致过拟合, 所以合适的参数对 LSTM 网络训练尤为重要. 如引言所述, STA 算法相比于传统的智能优化算法具有全局性、最优性、快速性等特点, 本文将选用该算法优化双层 LSTM 的神经元个数、训练次数、学习率, STA-LSTM 优化算法流程如图 1(b) 所示.

本文将数据集划分为训练集和测试集, 测试集为数据集的最后 24 个数据, 其余部分为训练集. 使用 STA 算法得到的状态集及训练集训练 LSTM, 通过测试集测试训练好的模型. 根据适应度函数不断调整 LSTM 参数, 找到一组参数使得 LSTM 预测的误差值最小. STA-LSTM 优化算法参数具体步骤如下.

step 1: 对数据集进行预处理. 为了避免数据集之间存在较大差异以及更好地训练数据, 需要对数据集做归一化处理.

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}. \quad (21)$$

step 2: 初始化状态转移算法的搜索个体数 SE 和 α 、 β 、 γ 、 δ 四个因子的值, 设置迭代次数 n 和搜索范围.

step 3: 确定适应度函数. 以 LSTM 模型的均方误差作为适应度函数, STA 算法的目的是找到一组参数使得 LSTM 预测的误差最小.

$$\text{fit} = \frac{1}{n} \sum_{i=1}^n (y_i - Y_i)^2, \quad (22)$$

其中 y_i 和 Y_i 分别是实际值和模型的预测值.

step 4: 得到初始状态集, 根据初始状态集和训练集训练 LSTM, 将测试集代入训练好的 LSTM, 得到初始最佳适应度函数值.

step 5: 状态转移算法首先调用伸缩变换, 根据伸缩变换产生新的状态集, 将新的状态集和训练集代入 LSTM 训练, 将测试集代入训练好的 LSTM, 根据适应度函数计算伸缩变换后的适应度函数值, 当伸缩变换后适应度函数值小于当前最佳适应度函数值时, 将伸缩变换后的适应度函数值更新为当前最佳适应

度函数值, 将伸缩变换后的状态集更新为当前最优状态集, 否则不更新. 当更新完最佳适应度函数值和最优状态集后, 状态转移算法又会调用平移变换产生新的状态集, 同样再一次将新的状态集和训练集代入 LSTM 训练, 将测试集代入训练好的 LSTM, 根据适应度函数计算平移变换后的适应度函数值, 当平移变换后适应度函数值小于当前最佳适应度函数值时, 将平移变换后的适应度函数值更新为当前最佳适应度函数值, 将平移变换后的状态集更新为当前最优状态集, 否则不更新. 后续会继续调用旋转、轴向变换, 更新解的策略与上述内容一致.

step 6: 迭代次数是否达到最大值, 如果是, 则退出循环, 输出结果, 否则回到 step 5.

step 7: 代入优化参数, 将 STA 优化的最优解作为 LSTM 的最终参数, 代入模型进行训练预测.

2.3 算法3 (STA-ARMA优化算法)

利用 ARMA 模型对细节捕捉好、时间复杂度低等优点, 对平稳的细节子序列进行 ARMA 模型预测, 采用 STA 算法对 ARMA 模型寻找最优的阶数.

STA-ARMA 算法具体过程如下:

step 1: 将通过平稳性检测的细节子序列划分测试集和训练集.

step 2: STA 算法随机初始化 p 、 q 值.

step 3: p 、 q 值赋值给 ARMA 模型.

step 4: 测试集输入 ARMA 模型.

step 5: STA 算法根据式 (4)~(7) 和 (22) 更新 p 、 q 值.

step 6: 达到迭代次数结束搜索过程.

step 7: 将最优解作为 ARMA 的参数, 将优化后 p 、 q 值赋值给模型.

step 8: 代入测试集进行预测.

3 实验与分析

3.1 实验数据

为验证本文方法对不同电力系统数据的预测性能, 在国家统计局获取了中国水力发电 1995 年~2021 年 7 月发电量, 数据采集频率为每月一次, 单位为亿千瓦时, 共计 257 条数据. 从中国水力发电数据 (data 1) 曲线图 2(a) 可以看出, 此类电力数据具有明显的周期性, 上升趋势属于不平稳序列. 美国某地区电力负荷数据 (data 2) 为 2015 年 7 月 27 日~2017 年 7 月 23 日数据, 采集频率为每天一次, 共计 728 条, 单位为亿瓦时, 数据曲线呈现高度非平稳、非线性、无明显周期性等特点, 如图 2(b) 所示. 巴拿马电力负荷数据 (data 3) 来自 Kaggle 公共数据集平台, 为 2020 年 6 月 2 日~2020 年 6 月 26 日数据, 采集频率为 1 次/h, 共计

600条,单位为亿千瓦时,数据曲线虽然周期性显著,但其波动性较大,如图2(c)所示。

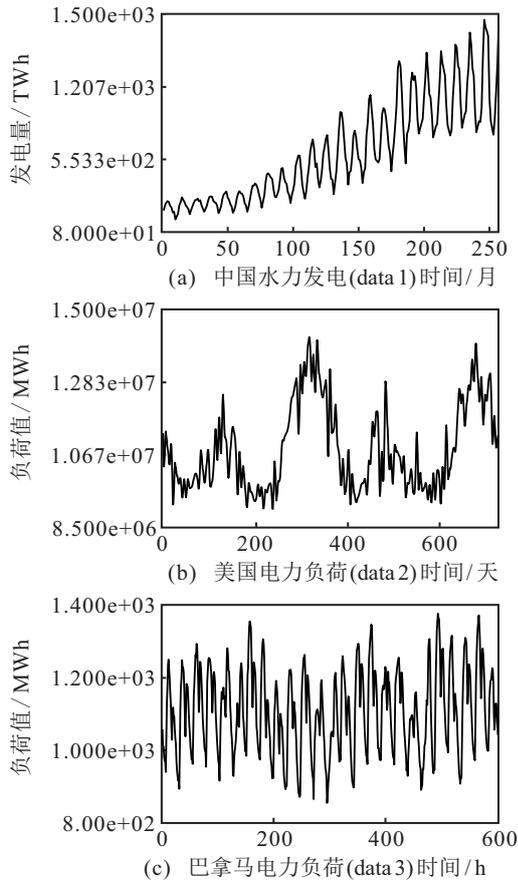


图2 3组电力数据

3组数据相关属性和小波分解数据平稳性分析分别如表1和表2所示.如算法1所述,小波变换级数依据平稳性检测结果而定,对细节子序列依次检测,直到第1个未通过平稳性检测的细节子序列,记该层为小波变换的级数,所以data 1、data 2、data 3小波变换的级数分别为4、5、5。

表1 3组电力数据相关属性

数据编号	长度	最小值	最大值	均值	标准差	偏度	峰度	
data 1	257	86	1463.1	545.9	339	0.71	-0.45	
data 2	728	9048	94214	176372	10828533	1247680	0.74	-0.55
data 3	600	855.1	1374.9	1109.3	115	0.02	-0.18	

表2 小波分解数据平稳性分析(0: 非平稳, 1: 平稳)

数据编号	D ₁	D ₂	D ₃	D ₄	D ₅	D ₆	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆
data 1	1	1	1	1	0	0	0	0	0	0	0	0
data 2	1	1	1	1	1	0	0	0	0	0	0	0
data 3	1	1	1	1	1	0	0	0	0	0	0	0

3.2 评价标准

由于实验采用了3组数据,为了进行横向对比,以验证本预测模型的稳定,选择均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean

absolute percent error, MAPE)作为评价标准,即

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - Y_i)^2}, \quad (23)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - Y_i|, \quad (24)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - Y_i|}{y_i}. \quad (25)$$

3.3 结果与分析

3.3.1 STA与PSO优化性能对比

选择式(22)的适应度函数作为PSO算法、STA算法优化的目标函数,进行优化性能比较.图3为不同数据集在未进行小波变换前的原始数据、STA算法与PSO算法适应度函数迭代次数变化曲线,对于data 1, PSO算法在迭代2次后,适应度函数的值就未发生变化,而STA算法即使一开始寻找的解的极值点没有PSO低,但随着迭代次数的增加,寻找到的极值点一次比一次低,最终适应度函数的极值点比PSO更低.在data 2与data 3中,STA算法一开始就得到了比PSO算法更低的极值点,即使随着迭代次数的增加,两个算法都在不断寻找更低的极值点,但最终STA算法寻找的极值点更小.由此可以得出,STA算法可以比较好地找到适应度函数的极小值。

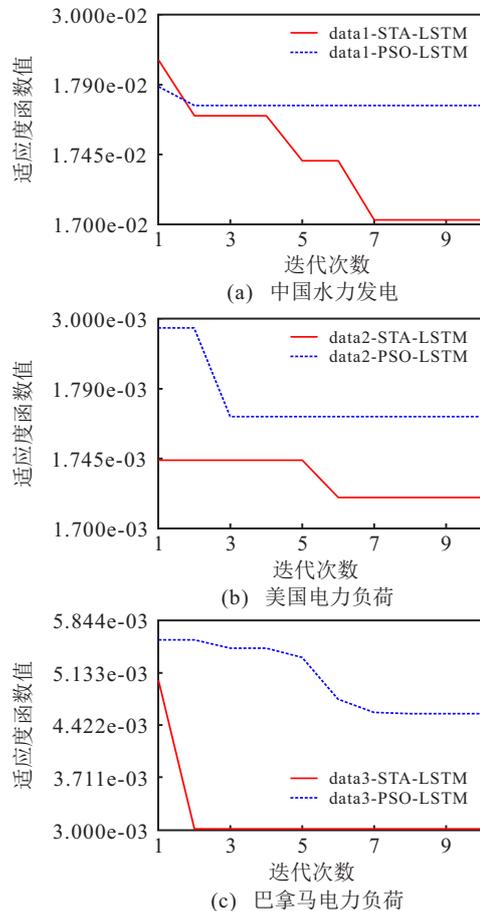


图3 STA与PSO优化性能对比

3.3.2 拟合效果比较

图4为data 1各种模型的部分拟合图,直接使用ARIMA建模,尽管能较为准确地刻画数据的波动,但是在长期趋势上还不够理想,例如在某些点原始数据的曲线较为平滑,而ARIMA模型在拟合时曲线较为锋利,对于数据的趋势拟合有时也会伴随着滞后现象.单一的LSTM网络虽然可以拟合数据的整体趋势,但对于数据点的峰值预测差距较大.从图4中显而易见的是LSTM网络拟合出的曲线较为光滑,丢失的细节较为严重,不能很好地拟合这类细节较多的数据.基于优化的PSO-LSTM和STA-LSTM模型与单一LSTM模型比较,整体的拟合效果有一定提升,降低了大部分数据点与真实曲线之间的差距.受制于电力数据曲线高度非线性特点,由图4不难发现,原始数据的曲线拐点较多,而PSO-LSTM和STA-LSTM模型对于这些点的处理与LSTM基本一致,大部分拐点的拟合都存在着拟合曲线过于光滑的问题,细节捕捉能力不强.STA-LSTM与PSO-LSTM区别在于STA算法与PSO算法相比能更进一步提高大部分数据点的峰值拟合.基于分解的WD-ARMA-LSTM混合模型较上述的ARIMA、LSTM、PSO-LSTM、STA-LSTM而言,能更准确地拟合出数据波动的细节以及波峰波谷所出现的时刻.虽然基于分解的混合模型可提高数据细节的拟合能力,但因受制于凭经验设置参数的局限性,会影响到序列峰值的预测精度.本文集成分解和优化的WD-STA-ARMA-LSTM混合方法对数据的拟合能力有较大的提升,例如 $t = 49$ 处(图4放大处),本文所提方法能够精确地拟合原始数据,得到了明显优于其他方法的效果.

通过对data 2、data 3的拟合结果进行对比分析,可以得到与data 1相似的结论.

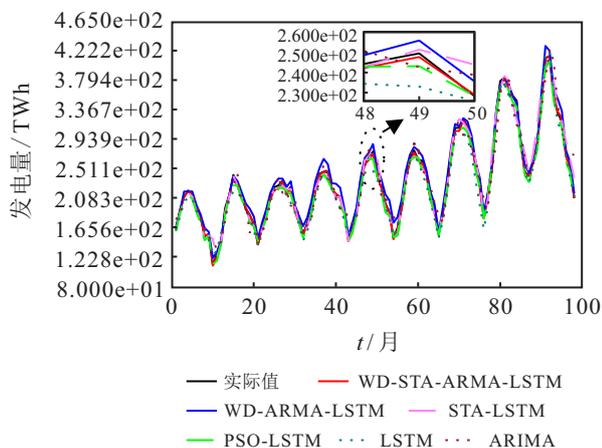


图4 data 1数据拟合

3.3.3 预测效果比较

图5(a)显示了本文所提方法WD-STA-ARMA-LSTM对data 1的预测结果及表3所示评价标准.

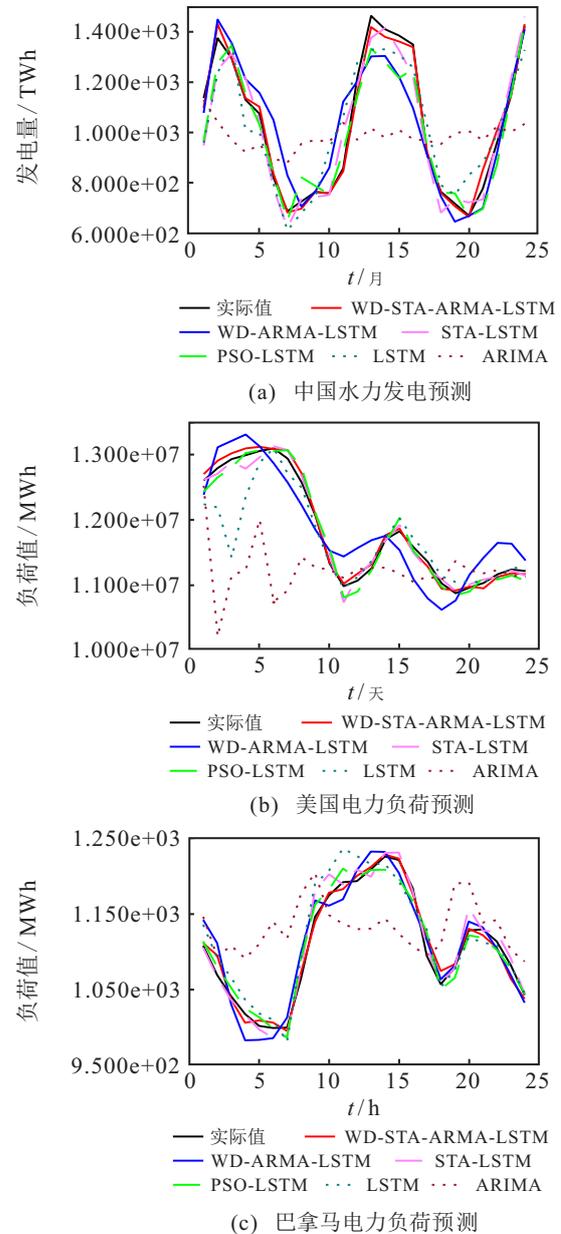


图5 3组数据预测

基于自适应混合优化的电力数据预测方法普遍优于其他方法,由图5(a)中的预测结果可以得出以下结论:

1) 基于单一模型的ARIMA模型预测数据的波动性较小,不能较好地预测出电力数据具有的特征,这些特征表现为非线性和非平稳,LSTM模型虽通过数据的趋势可以大致预测,但对每个数据点值的预测偏差较大.如表3所示,对于线性时间序列模型ARIMA的各项误差指数(RMSE、MAE、MAPE)的值分别为262.715、233.466、22.96%,采用深度学习网络模型的LSTM的值下降至104.556、89.953、9.216,每个

评价指标的值平均下降约 60%。说明深度学习网络对非线性、非平稳序列拥有良好的预测能力。

表 3 各模型预测误差

数据编号	模型	RMSE	MAE	MAPE / %
data 1	WD-STA-ARMA-LSTM	30.301	21.805	2.106
	STA-LSTM	74.659	56.993	5.583
	PSO-LSTM	79.954	62.1293	5.777
	WD-ARMA-LSTM	115.836	86.603	8.660
	LSTM	104.556	89.953	9.216
	ARIMA	262.715	233.466	22.96
data 2	WD-STA-ARMA-LSTM	98 857.9	80 362.91	0.681
	STA-LSTM	99 711.7	86 207.8	0.726
	PSO-LSTM	122 861.6	103 028	0.876
	WD-ARMA-LSTM	537 961.8	398 246.5	3.319
	LSTM	379 753.2	206 590.3	1.665
	ARIMA	10 612 345	709 164	5.661
data 3	WD-STA-ARMA-LSTM	10.733 1	8.438 2	0.766
	STA-LSTM	13.0167	9.706 01	0.895
	PSO-LSTM	14.013 8	11.671 9	1.050
	WD-ARMA-LSTM	20.414 4	17.581 9	1.600
	LSTM	23.286 3	19.519 6	1.749
	ARIMA	74.131 2	64.589 5	5.921

2) 基于优化的 STA-LSTM、PSO-LSTM 整体的预测趋势与 LSTM 模型近似,与单一模型的 LSTM 相比,STA-LSTM、PSO-LSTM 可以增强大部分数据点的峰值预测能力。STA-LSTM 虽然在数据预测前期表现略逊于 PSO-LSTM,但随着预测步数加深,STA 优化的 LSTM 整体曲线波动更接近真实曲线。虽然 STA 算法和 PSO 算法可以对 LSTM 的预测精度有一定的提高,但也存在着对数据波动细节把握不准以及对数据波峰波谷预测精度有待进一步提高的问题。PSO-LSTM 模型在 LSTM 模型的基础之上,各项评价指标的值平均下降约 30%,而 STA-LSTM 在 PSO-LSTM 之上各项评价指标的值进一步下降了约 6.03%。从侧面验证了 LSTM 参数的设置直接影响 LSTM 模型的预测精度和 STA 算法对 LSTM 优化能力优于 PSO 算法。

3) 基于固定 3 层分解的 WD-ARMA-LSTM 混合模型,此模型对比单一模型和优化模型,在预测前期,更能刻画出数据的细节,基本预测出了数据的折点,但随着预测步数的加深,模型的泛化能力有所减弱。基本分解的 WD-ARMA-LSTM 混合模型的各项指标虽然不及基于优化的 PSO-LSTM、STA-LSTM 模型,但其各项指标均优于单一模型,说明分解有利于提高模型的精度。

4) 基于自适应混合优化的电力数据预测方法整体上可以较好地预测数据的波动及走势,细节上不仅

预测出了数据的拐点,而且对于拐点的预测也更为精确。本文方法在表现良好的 STA-LSTM 模型上,各项指标进一步平均下降约 61%。通过科学客观的数值评价标准进一步验证了本文所提方法的良好预测能力。

5) 分析 data 2、data 3 的预测结果,如图 5(b) 和图 5(c) 所示,可以得到与 data 1 类似的结论。这得益于小波可将数据分解为不同的序列,分别利用 LSTM 独特的单元记忆结构、ARMA 模型对平稳序列的细节捕捉能力较好、STA 算法的优化能力等优点,能明显提高电力预测精度。

6) 文献[15]使用改进粒子群算法优化 LSTM 并对电力负荷进行预测,平均误差 MAPE 为 2.59%。本文选取 3 组不同电力系统数据,每一组数据的 MAPE 均比文献[15]低。文献[17]利用粒子群算法优化 ELM,预测未来 3h 的电力负荷,预测步数为 7 步,MAPE 为 1.1708%。本文预测步数为 24 步,data 2 和 data 3 两组数据集 MAPE 指标均明显优于文献[17]。

4 结 论

精确的电力系统数据预测能够为电力调度决策提供准确的数据支撑,有助于提升电力系统的可靠性和稳定性。本文提出了一种基于自适应混合优化的电力数据预测方法,与其他方法相比提高了电力预测精度。本文主要贡献如下:

1) 结合小波变换平稳性检测结果,将电力系统数据自适应分解,得到多个平稳细节子序列和一个非平稳近似子序列。

2) 利用 ARMA 模型对细节捕捉好、时间复杂度低等优点,对通过平稳性检测的细节子序列进行 ARMA 建模预测。

3) 运用 LSTM 模型对近似项等非平稳项拟合较好的优点,对去掉细节信息的非平稳近似子序列进行 LSTM 建模,较大程度降低了神经网络建模的复杂度。

4) 采用 STA 算法对 LSTM 参数、ARMA 阶数分别进行优化。

参考文献(References)

- [1] Wu F, Cattani C, Song W Q, et al. Fractional ARIMA with an improved cuckoo search optimization for the efficient short-term power load forecasting[J]. Alexandria Engineering Journal, 2020, 59(5): 3111-3118.
- [2] Singh B, Pozo D. A guide to solar power forecasting using ARMA models[C]. 2019 IEEE PES Innovative Smart Grid Technologies Europe. Bucharest, 2019: 1-4.

- [3] Dash S K, Dash P K. Short-term mixed electricity demand and price forecasting using adaptive autoregressive moving average and functional link neural network[J]. *Journal of Modern Power Systems and Clean Energy*, 2019, 7(5): 1241-1255.
- [4] Lin B D, Zhang X Y, Zhang M, et al. Improved genetic algorithm-based research on optimization of least square support vector machines: An application of load forecasting[J]. *Soft Computing*, 2021, 25(18): 11997-12005.
- [5] Peng W, Xu L W, Li C D, et al. Stacked autoencoders and extreme learning machine based hybrid model for electrical load prediction[J]. *Journal of Intelligent & Fuzzy Systems*, 2019, 37(4): 5403-5416.
- [6] Ge Q B, Jiang H Y, He M G, et al. Power load forecast based on fuzzy BP neural networks with dynamical estimation of weights[J]. *International Journal of Fuzzy Systems*, 2020, 22(3): 956-969.
- [7] Lin R H, Yang F C, Gao M Y, et al. AUD-MTS: An abnormal user detection approach based on power load multi-step clustering with multiple time scales[J]. *Energies*, 2019, 12(16): 3144.
- [8] Zheng C, Wang S R, Liu Y L, et al. A novel RNN based load modelling method with measurement data in active distribution system[J]. *Electric Power Systems Research*, 2019, 166: 112-124.
- [9] Sheng Z Y, Wang H W, Chen G, et al. Convolutional residual network to short-term load forecasting[J]. *Applied Intelligence*, 2021, 51(4): 2485-2499.
- [10] Tan M, Yuan S P, Li S H, et al. Ultra-short-term industrial power demand forecasting using LSTM based hybrid ensemble learning[J]. *IEEE Transactions on Power Systems*, 2020, 35(4): 2937-2948.
- [11] Ciechulski T, Osowski S. High precision LSTM model for short-time load forecasting in power systems[J]. *Energies*, 2021, 14(11): 2983.
- [12] Jahangir H, Tayarani H, Gougheri S S, et al. Deep learning-based forecasting approach in smart grids with microclustering and bidirectional LSTM network[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(9): 8298-8309.
- [13] Li W, Quan C X, Wang X Y, et al. Short-term power load forecasting based on a combination of VMD and ELM[J]. *Polish Journal of Environmental Studies*, 2018, 27(5): 2143-2154.
- [14] 杨杰, 霍志红, 何永生, 等. 基于小波与最小资源分配网络的超短期风电功率预测研究[J]. *电力系统保护与控制*, 2018, 46(9): 55-61.
(Yang J, Huo Z H, He Y S, et al. Ultra-short-term wind power prediction based on wavelet and minimum resource allocation network[J]. *Power System Protection and Control*, 2018, 46(9): 55-61.)
- [15] 魏腾飞, 潘庭龙. 基于改进 PSO 优化 LSTM 网络的短期电力负荷预测[J]. *系统仿真学报*, 2021, 33(8): 1866-1874.
(Wei T F, Pan T L. Short-term power load forecasting based on LSTM neural network optimized by improved PSO[J]. *Journal of System Simulation*, 2021, 33(8): 1866-1874.)
- [16] Abdolrasol M G M, Mohamed R, Hannan M A, et al. Artificial neural network based particle swarm optimization for microgrid optimal energy scheduling[J]. *IEEE Transactions on Power Electronics*, 2021, 36(11): 12151-12157.
- [17] Xie K, Yi H, Hu G Y, et al. Short-term power load forecasting based on Elman neural network with particle swarm optimization[J]. *Neurocomputing*, 2020, 416: 136-142.
- [18] Dickey D A, Fuller W A. Distribution of the estimators for autoregressive time series with a unit root[J]. *Journal of the American Statistical Association*, 1979, 74(366a): 427-431.
- [19] 周晓君, 阳春华, 桂卫华. 状态转移算法原理与应用[J]. *自动化学报*, 2020, 46(11): 2260-2274.
(Zhou X J, Yang C H, Gui W H. The principle of state transition algorithm and its applications[J]. *Acta Automatica Sinica*, 2020, 46(11): 2260-2274.)

作者简介

曾朝晖(1977—), 女, 副教授, 博士, 从事小波分析理论及应用、人工智能、时间序列分析、铝电解、智能电网等研究, E-mail: zzh@xtu.edu.cn;

赵会勇(1994—), 男, 硕士生, 从事智能计算与信息处理的研究, E-mail: 202021002524@smail.xtu.edu.cn;

罗恩韬(1978—), 男, 教授, 博士, 从事网络安全、大数据隐私计算等研究, E-mail: luontaohouse@163.com;

张英豪(1997—), 男, 硕士生, 从事智能计算与信息处理的研究, E-mail: 1343976313@qq.com;

杨阳(1998—), 男, 硕士生, 从事智能计算与信息处理的研究, E-mail: 1095483641@qq.com;

严一泰(1998—), 男, 硕士生, 从事智能计算与信息处理的研究, E-mail: 1442598257@qq.com.