

深度学习在电力负荷预测中的应用

张建寰 吉莹 陈立东

(厦门大学航空航天学院 福建 厦门 361000)

摘要: 针对电力负荷预测中存在的随机性、不确定性的问题,结合深度学习算法具有很强的自适应感知能力等特点,采用目前较为主流的深度学习方法,如长短时记忆(LSTM)网络、门循环单元(GRU)神经网络和栈式自编码器(SAE),分别研究其应用于电力负荷预测时的效果。研究发现,将历史负荷数据作为三种深度学习预测模型的输入时,三种预测模型的负荷预测精度指标评估结果各有不同。因此,为了全面评估三种预测模型的预测效果,提出将不同时间段内的相同历史负荷数据作为预测模型输入对比各模型的负荷预测精度,从中找出最佳的预测模型。仿真结果验证了三种预测模型在电力负荷预测应用中的可行性,且发现在单输入因素时LSTM模型的预测精度相对较高。因此,在后续研究中,可以考虑以LSTM预测模型作为基础预测模型,结合更多的负荷影响因素进行改进,以提高负荷预测精度。

关键词: 深度学习; 长短时记忆; 门循环单元; 循环神经网络; 栈式自编码器; 负荷预测; 预测精度

中图分类号: TH3 **文献标志码:** A **DOI:** 10.16086/j.cnki.issn1000-0380.2018060050

Application of Deep Learning in Power Load Forecasting

ZHANG Jianhuan, JI Ying, CHEN Lidong

(School of Aerospace Engineering, Xiamen University, Xiamen 361000, China)

Abstract: Aiming at the problems of randomness and uncertainty in power load forecasting, combining with deep learning algorithm, which has strong adaptive sensing ability, and by adopting the current mainstream deep learning methods, such as long-short-time memory (LSTM), gated recurrent unit (GRU) neural network and stacked automatic encoders (SAE), the prediction effects of power load forecasting are studied respectively. It is found in the study that when historical load data are used as input to three deep learning prediction models, the load forecasting accuracy indicators of the three prediction models have different evaluation results. In order to comprehensively evaluate the prediction effects of the three prediction models, the same historical load data in different time periods are used as the predictive model input, and the load prediction accuracy of each model are compared to find the optimal model. The simulation results verify the feasibility of three prediction models in power load forecasting applications, and find that the prediction accuracy of LSTM model is relatively high when single input factors are used. Therefore, in the follow-up study, the LSTM prediction model can be considered as the basic prediction model, combined with more load influencing factors to improve the load prediction accuracy.

Keywords: Deep learning; Long-short-term memory (LSTM); Gated recurrent unit (GRU); Recurrent neural networks (RNN); Stacked auto-encoder (SAE); Load forecasting; Prediction accuracy

0 引言

负荷预测作为电力系统调度的重要组成部分,其预测精度或预测误差对电网后续运行的状态评估、安全性、经济性等具有重要意义^[1-3]。随着机器学习的快速发展,目前负荷预测多采用前馈神经网络、支持向量机等机器学习技术。但由于其只是停留在浅层的学

习,难以提取负荷序列的深层特征,预测精度有待进一步提升。

深度学习负荷预测领域表现出的自适应学习、感知能力,可以有效解决浅层预测模型对非线性负荷数据和多因素影响的认识能力不足,以及人为干扰等问题^[4-5]。因此,为提高负荷预测的精度,本文将深度学习中的几个典型模型应用到负荷预测中,进行短期电

收稿日期: 2018-06-05

基金项目: 国家电网公司科技基金资助项目(JL71-16-006)

作者简介: 张建寰(1966—),男,博士,教授,主要从事光电技术、自动化、人工智能等方向的研究, E-mail: aeolus@xmu.edu.cn;

吉莹(通信作者),女,在读硕士研究生,主要从事深度学习、机器学习、负荷预测等方向的研究, E-mail: 1311293893@qq.com

力负荷预测, 并采用常用的模型评价指标对几种模型的负荷预测进行评估和对比。

1 电力负荷预测及深度学习简介

1.1 电力负荷预测现状

电力系统的负荷预测是根据电力系统的运行特性及其他诸多因素, 在满足一定精度要求下预测电力系统未来某些特定时刻的负荷数据。由于电能难以大量存储且用户端电力需求时刻变化, 这就要求系统发电量要和负荷变化时刻保持动态平衡。由于负荷预测是根据过去的数值来推测未来的数值, 因此负荷预测的研究对象是一个不确定、复杂的随机事件, 具有不准确性、条件性、时间性和多方案性等特点。

电力负荷预测, 根据其预测周期, 可以分为长期、中期、短期以及超短期负荷预测。其中, 短期负荷预测研究较多, 其预测目标一般是预测某个地区未来一天或者一周的用电量数据。相较于其他周期的负荷预测, 短期负荷预测更具实际意义, 是制定发电计划和提供调度的重要参考依据。短期负荷预测的方法有很多, 传统的负荷预测主要方法有: 基于时间序列的自回归滑动平均模型 (autoregressive moving average model, ARMA)、灰度预测和线性回归分析法等。这些模型的预测结构较为简单, 应用广泛。但是它们对序列数据平稳型要求较高。大多数情况下, 这些模型只是利用历史负荷数据对未来负荷进行预测, 考虑因素单一, 在某些情况下预测的精度会受到很大的影响。

1.2 深度学习简介

深度学习 (也称为深度结构学习或逐层学习) 不是特定于任务的算法, 而是作为以数据学习规律为代表的、更广泛的机器学习方法系列的一部分。它的学习方式分为监督学习、半监督学习和无监督学习。作为机器学习中的一个新的研究领域, 它的原理是通过建立神经网络模拟人脑来分析学习, 并试图模仿人脑的机制去解释事物原理。深度学习架构, 比如深度神经网络、深度信念网络和递归神经网络, 目前已被广泛应用到计算机视觉、图像处理、自然语言处理、语音识别、音频识别、社交网络过滤、机器翻译、生物信息学、药物设计和棋盘游戏程序等领域。机器学习的成果可与人类专家媲美, 甚至在某些情况下要优于人类专家。

2 三种深度学习模型原理

2.1 LSTM 神经网络原理

长短时记忆 (long-short-term memory, LSTM) 神经网络是一种特殊的循环神经网络 (recurrent neural

networks, RNN) 类型, 可以学习长期依赖信息。其由 Hochreiter & Schmidhuber 于 1997 年提出, 近期取得了改良和推广。典型的 RNN 结构如图 1 所示。RNN 神经网络内部节点定向链接成环。相比于前馈神经网络, 它的本质特征是在内部的处理单元中既有反馈连接, 又有前馈连接。因此, 它可以利用结构的记忆功能来处理任意时间序列, 更适用于不分段的手写识别或者语音识别等^[6-7]。

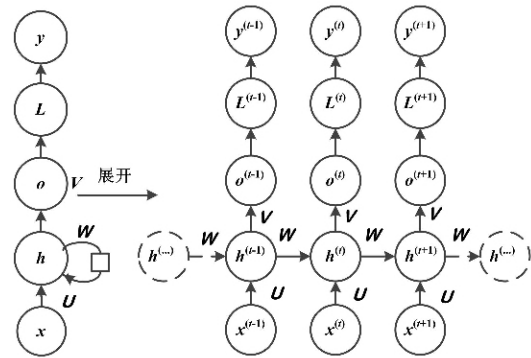


图 1 RNN 结构图

Fig. 1 RNN structure

图 1 中: X 为 RNN 神经网络的输入; h 为隐含层; 损失 L 用来衡量每个 O 与相应的训练目标 y 的距离; 权重矩阵 U 为输入到隐藏层的权重; 权重矩阵 W 为隐藏层到隐藏层的连接权重; 权重矩阵 V 为隐藏层到输出层的权重矩阵。

RNN 神经网络的局限性在于, 随着时间间隔的不断增大, 它会出现梯度消失或梯度爆炸的问题, 并且其结构很容易依赖于激活函数和网络参数。基于上述问题, 出现了 RNN 的变体 LSTM 神经网络^[3]。LSTM 典型结构如图 2 所示。




图 2 LSTM 典型结构图

Fig. 2 Typical LSTM structure

图 2 中, 每条线表示一个完整的向量, 即从一个节点的输出到其他节点的输入。

在标准的 RNN 结构中, 其重复的神经网络模块的链式形式只包含一个非常简单的结构, 如 \tanh 层 (如

图1所示)。LSTM 拥有一个不同的内部结构。它不是只有单一的神经网络层,而是有四个,并且以特殊的方式进行交互。根据图2所示,可以用以下几个公式解释 LSTM 循环模型单个循环体的结构。

输入门:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b) \quad (1)$$

遗忘门:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2)$$

候选时刻记忆单元:

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + bc) \quad (3)$$

当前时刻记忆单元:

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (4)$$

输出门:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

输出:

$$h_t = o_t \tanh(C_t) \quad (6)$$

LSTM 和 RNN 都是利用随时间反向传播(back propagation through time, BPTT)、随机梯度或者其他算法,优化去拟合模型的最佳参数。由于 LSTM 更新的状态值 C_t 的表达式是相加的形式,因此不容易出现状态值逐渐接近 0 的情况,即梯度消失现象。

2.2 GRU 神经网络原理

并非所有的 LSTM 网络结构都如图 2 所示。LSTM 神经网络目前包含了很多的变体,其中较流行的一种是变体门循环单元(gated recurrent unit, GRU)神经网络,其结构如图 3 所示。它既保持了 LSTM 的效果,又使得结构更为简单。LSTM 实现了三个门(遗忘门、输入门和输出门)的计算,而 GRU 实现了更新门和重置门的计算,即图 3 中的 Z_t 和 r_t 。




图3 GRU 结构图
Fig.3 GRU structure

GRU 的前向传播方式为:

$$r_t = \sigma(W_r[h_{t-1}, x_t]) \quad (7)$$

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (8)$$

$$\tilde{h}_t = \tanh(W_h[r_t h_{t-1}, x_t]) \quad (9)$$

$$h_t = (1 - z_t) h_{t-1} + z_t \tilde{h}_t \quad (10)$$

$$y_t = \sigma(W_o h_t) \quad (11)$$

2.3 SAE 编码器原理

自编码器(autoencoder, AE)是构建栈式自编码器(stacked auto-encoder, SAE)模型的基本单元,通过编码和解码两个功能去逼近一个使得输出接近于输入的恒等函数。自编码器结构如图 4 所示。其包含可视层、隐藏层和重构可视层,是一个类似于三层神经网络的结构^[8]。

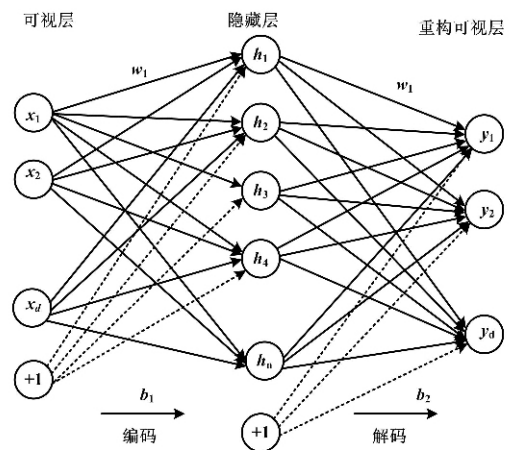


图4 自编码器结构图
Fig.4 AE structure

在编码阶段,将 X_i 作为特征向量输入到隐藏层中,通过式(12)完成特征提取,得出编码结果 h ; 然后使用式(13)隐含层输出结果进行解码重构,输出解码结果 $y(x_i)$ 。

$$h = f(w_1 x_i + b_1) \quad (12)$$

$$y(x_i) = g(w_2 h + b_2) \quad (13)$$

式(12)、式(13)中, w_1 和 w_2 分别表示可视层与隐藏层、隐藏层与重构可视层的连接权值矩阵, b_1 和 b_2 分别表示可视层与隐藏层、隐藏层与重构可视层的偏置值矩阵。 $f(\cdot)$ 和 $g(\cdot)$ 是对应节点的变换函数,一般采用 sigmoid 函数。单个自编码器通过反向传播算法训练网络,以最小化损失函数 L 来求解满足逼近条件 $y(x_i) \approx x_i$ 的参数 $\{w, b\}$ 的值。自编码器损失函数 C 可表示为:

$$C(w, b) = \frac{1}{2N} \sum_{i=1}^N \sum_{j=1}^d [y(x_{ij}) - x_{ij}]^2 + \frac{\lambda}{2} \sum_i \sum_j [w_{ij}(\theta)]^2 + \gamma \sum_{k=1}^n KL(\hat{\rho} \rho_k) \quad (14)$$

式中: d 为输入层节点个数; λ 为权重衰减系数; $KL(\hat{\rho}\rho_k)$ 为稀疏惩罚因子; γ 为稀疏项权重; ρ 一般取值为 0.05。

从图 4 可以发现,每个单元输入层与输出层的神经元数量相等。在实际使用中,SAE 是由多个 AE 自

编码器叠加起来的,并且逐个训练。只不过从第二个自编码器开始,其输入向量就变成了前一个编码器的隐藏层。

SAE 模型结构如图 5 所示。其中,虚线框的结构在 SAE 堆叠模型结构中不出现。

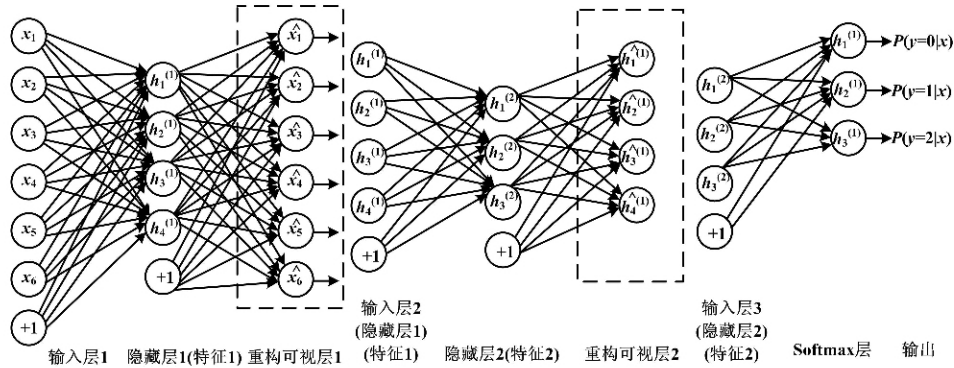


图 5 SAE 模型结构图

Fig. 5 SAE model structure

3 负荷预测模型建立

3.1 数据预处理

目前,电网系统收集了大量的电量信息,但是仍不可避免地存在数据缺失或者数据异常的情况^[5]。如果这些数据不加以处理直接输入神经网络预测模型,必然会导致很大的误差。因此,需要对缺失的数据进行填补,并对异常数据进行识别和修正。这就是数据预处理所要做的工作^[9-10]。

(1) 异常数据的识别和修正处理。

正常情况下,电力负荷数据都是连续平滑的,相邻时刻点的负荷数据值不会相差太大。如果差距明显很大,那就可能是异常数据。本文中对异常数据采取水平处理方法修正,具体修正方法如下。

如果:

$$\max[|Y(d,t) - Y(d,t-1)|, |Y(d,t) - Y(d,t+1)|] > \varepsilon(t) \quad (15)$$

那么:

$$Y(d,t) = \frac{Y(d,t-1) + Y(d,t+1)}{2} \quad (16)$$

式中: ε 为阈值; t 为采样的时间点。

本文中的数据是每隔半小时的数据,因此 t 的取值范围为 1~48, $Y(d,t+1)$ 表示第 d 天($t+1$) 时刻的电力负荷值。

(2) 缺失数据的补充。

考虑到负荷数据的周期性,本文对负荷数据中意外丢失的数据作拉格朗日插值法处理。

(3) 数据样本归一化。

归一化操作的公式为:

$$P_d = \frac{P - P_{\min}}{P_{\max} - P_{\min}} \quad (17)$$

式中: P 为预处理后的输入样本矩阵; P_d 为归一化处理后的数据矩阵; P_{\max} 为历时输入数据中的最大值; P_{\min} 为历时输入数据中的最小值。

3.2 建立基于负荷预测的深度学习模型

本次试验中,采用的数据样本为某地区 2016 年整年的负荷数据,采样周期为每半小时一次。将预处理后的数据分别输入构建的 LSTM、GRU 和 SAE 模型中。

LSTM 和 GRU 按照正常的 RNN 网络进行训练。由于电脑硬件的限制,在模型的训练中,LSTM 和 GRU 模型都只设计了两个隐藏层,SAE 模型中构建了三个单独的自动编码器。

自编码器训练的原理如前文所述,就是通过 encode 层对输入进行编码,即提取特征;然后,用 encode 层参数的转置成特征矩阵再加偏置值矩阵,以此重构输入;最后,利用最小化重构的输入和实际输入值的损失函数训练模型参数。SAE 的训练过程是多个 AE 分别训练,第一个 AE 训练完以后,其输出作为第二个 AE 的输入,以此类推。训练完成后,将所有 AE 的隐藏层连接起来,就组成了 SAE 网络模型。按照之前各自 AE 训练好的权值作为初始化权值,对整个网

络进行参数微调,优化全局网络参数。

3.3 预测结果分析

本文采用了平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE)、相对百分误差绝对值的平均值 (mean absolute percentage error, MAPE)、R 平方 (R^2) 和可释方差得分 (explained_variance_score) 这五个指标,分别对模型的预测结果进行评估和对比。

$$MAE(x, h) = \frac{1}{m} \sum_{i=1}^m |y^{(i)} - h(x^{(i)})| \quad (18)$$

$$RMSE(x, h) = \sqrt{\frac{1}{m} \sum_{i=1}^m [y^{(i)} - h(x^{(i)})]^2} \quad (19)$$

$$MAPE = \sum_{i=1}^m \left| \frac{y^{(i)} - h(x^{(i)})}{y^{(i)}} \right| \times \frac{100}{m} \quad (20)$$

$$\text{explained_variance_score}[y^{(i)}, h(x^{(i)})] = 1 - \frac{\text{Var}\{y^{(i)} - h(x^{(i)})\}}{\text{Var}\{y^{(i)}\}} \quad (21)$$

式中: $h(x^{(i)})$ 为网络输出的预测值; $y^{(i)}$ 为实际负荷值。

本文以三种算法模型作为对比算法,分别将 2016 年一整年的负荷数据和 2015 ~ 2016 年两年负荷数据输入模型,对比各个模型的预测结果。编码实现基于 Python3.6 平台完成。表 1 展示了三个算法模型以 2016 全年数据训练模型的负荷预测指标评估结果,表 2 展示了三个算法模型以 2015 ~ 2016 数据训练模型的负荷预测指标评估结果。

表 1 负荷预测指标评估结果 (2016)
Tab. 1 Evaluation results of load forecasting indicators (2016)

算法模型	EVS	MAPE/%	MAE	MSE	RMSE	R^2
LSTM	0.943	5.34	37.4	2 122.5	46.071	0.943
GRU	0.932	8.13	57.8	5 828.6	76.345	0.935
SAEs	0.915	6.11	43.2	2 699.4	51.995	0.915

表 2 负荷预测指标评估结果 (2015 ~ 2016)
Tab. 2 Evaluation results of load forecasting indicators (2015 ~ 2016)

算法模型	EVS	MAPE/%	MAE	MSE	RMSE	R^2
LSTM	0.953	4.98	34.8	1 909.4	43.70	0.952
GRU	0.936	6.95	41.2	4 147.6	64.40	0.937
SAEs	0.928	5.61	39.4	2 241.0	47.34	0.926

由表 1 和表 2 可知,无论是对于负荷的长期预测还是短期预测,LSTM 预测算法各个指标评价结果均优于其他预测模型。当以 2016 年的负荷数据作为训

练样本时,LSTM 负荷预测的预测误差达到 5.34%;当以 2015 至 2016 两年的负荷数据作为训练样本时,LSTM 负荷预测的误差可以降低至 4.98%。

但由结果可知,当数据数据类型只有历史负荷数据时,三种模型的负荷预测效果都不是很理想,误差皆超过 3%。其主要原因是影响负荷的因素有很多,例如节假日、气候状况、温度等。因此,进行负荷预测时,如果只考虑历史负荷数据,误差会相对较大。但是通过以上三个模型的预测结果评估对比可知,LSTM 预测模型更适用于负荷预测,并且输入的历史负荷训练数据时间越长,越有利于提高模型的预测准确度。在下一步工作中,考虑以 LSTM 模型作为基础进行改进,并对输入数据加入更多的特征(例如温度、气候、节假日等),以提高负荷的预测精度。

4 结束语

电力系统的海量负荷数据为电网负荷的特性分析和高精度、复杂的预测模型的奠定了基础。传统的负荷预测模型的结构较为简单,且考虑因素单一。而前馈神经网络、支持向量机等机器学习技术只是停留在浅层的学习,难以提取负荷序列的深层特征,模型的泛化性受到了限制,预测精度有待进一步提升。因此,本文将深度学习算法模型应用到负荷预测领域,主要对比了 LSTM、GRU 和 SAE 三种算法的预测效果,并通过对比预测精度来挖掘较为适合负荷预测的基础模型。在今后的研究中,会研究更多影响负荷预测的因素,并将其输入到神经网络模型中,以优化负荷预测模型的结构、提高预测精度;同时,考虑加入更多的顶层预训练器,以实现更精准的负荷预测。

参考文献:

- [1] 吴润泽,包正睿,宋雪莹,等.基于深度学习的电网短期负荷预测方法研究[J].现代电力,2018,35(2):43-48.
- [2] 樊雅琴,王炳皓,王伟,等.深度学习国内研究综述[J].中国远程教育,2015(6):27-33+79.
- [3] 程宇也.基于人工神经网络的短期电力负荷预测研究[D].杭州:浙江大学,2017.
- [4] 马锋,吴海伟,谈永伟.基于深度学习算法的主动配电网负荷预测研究[A].中国电力科学研究院.2017 智能电网新技术发展与应用研讨会论文集[C]//中国电力科学研究院,2017:6.
- [5] 单成龙.基于深度学习的电力负荷预测[D].湘潭:湘潭大学,2017.
- [6] 陈亮,王震,王刚.深度学习框架下 LSTM 网络在短期电力负荷预测中的应用[J].电力信息与通信技术,2017,15(5):8-11.

(下转第 17 页)

SOC 值的下降,有一个略微上升的过程,将 SOC 值与 R_0 进行多项式拟合,得到 R_0 多项式拟合曲线,如图 10 所示。




图 10 R_0 多项式拟合曲线

Fig. 10 R_0 polynomial fitting curve

极化内阻 R_p 随 SOC 值变化极小,且无明显上升或下降趋势。因此,选取其平均值作为极化内阻值。极化电容 C_p 随 SOC 值的减小呈逐渐上升的趋势,得到 C_p 多项式拟合曲线如图 11 所示。




图 11 C_p 多项式拟合曲线

Fig. 11 C_p polynomial fitting curve

4 结束语

本文以磷酸铁锂电池为对象,进行了充放电试验和 OCV-SOC 非线性曲线辨识试验,并分析其单体

电池的部分工作特性。权衡复杂度与准确度选择戴维南等效电路模型,采用 HPPC 测试进行参数辨识,为今后实际应用、建模仿真和电池管理系统设计提供了试验依据。

参考文献:

[1] 李哲. 纯电动汽车磷酸铁锂电池性能研究[D]. 北京: 清华大学, 2011.

[2] 张智群. 电动汽车用磷酸铁锂电池动态特性建模与仿真研究[D]. 西安: 长安大学, 2016.

[3] HE H W, XIONG R, FAN J X. Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach[J]. Energies 2011, 4(4): 582-598.

[4] KIM T, WANG Y B, FANG H Z. Model-based condition monitoring for lithium-ion batteries[J]. Power Sources 2015, 295: 16-27.

[5] 凡旭国, 周金治. 基于 PNGV 模型和高斯-厄米特滤波的 SOC 估算研究[J]. 自动化仪表, 2017, 38(12): 21-26.

[6] 冯飞, 宋凯, 逯仁贵, 等. 磷酸铁锂电池组均衡控制策略及荷电状态估计算法[J]. 电工技术学报, 2015, 30(1): 22-29.

[7] 李思. 电动汽车锂离子电池等效电路模型的参数辨识研究[D]. 北京: 北京理工大学, 2015.

[8] 王顺利, 尚丽平, 李占锋, 等. 基于滑动平均的锂电池关键参量检测方法研究[J]. 电子技术应用, 2015, 41(3): 141-144.

[9] WANG S L, FERNANDEZ C, SHANG L P, et al. An integrated online adaptive state of charge estimation approach of high-power lithium-ion battery packs [J]. Transactions of the Institute of Measurement and Control 2018, 40(6): 1892-1910.

[10] WANG S L, SHANG L P, LI Z F, et al. Online dynamic equalization adjustment of high-power lithium-ion battery packs based on the state of balance estimation[J]. Applied Energy 2016, 166: 44-58.

[11] 侯恩广, 乔昕, 刘广敏, 等. 动力锂电池 RC 等效模型辨识方法[J]. 电源技术, 2014, 38(2): 239-240.

[12] 张东华, 马燕, 陈思琪, 等. 锂电池模型参数估计与荷电状态估算研究[J]. 武汉理工大学学报(信息与管理工程版), 2015, 37(2): 179-182.

(上接第 12 页)

[7] 陈卓, 孙龙祥. 基于深度学习 LSTM 网络的短期电力负荷预测方法[J]. 电子技术, 2018, 47(1): 39-41.

[8] 董浩, 程鹏, 李玲玲. 深度学习算法在电力系统短期负荷预测中

的应用[J]. 电气时代, 2017(2): 82-84.

[9] 廖旋焕, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152.

[10] 姜云腾, 李萍. 基于改进粒子群神经网络短期负荷预测[J]. 电气技术, 2018, 19(2): 87-91.