

DOI: 10.7667/PSPC171255

结合受限玻尔兹曼机的递归神经网络电力 系统短期负荷预测

李若晨¹, 朱帆², 朱永利³, 翟羽佳⁴

(1. 国网河北省电力有限公司平山县供电分公司, 河北 平山 050400; 2. 首都师范大学哲学系, 北京 100037;
3. 华北电力大学控制与计算机工程学院, 河北 保定 071000; 4. 华北电力大学电力工程系, 河北 保定 071000)

摘要: 短期负荷预测的重要性随着电力企业的发展不断提高。传统的负荷预测虽然已经发展相对成熟, 但现阶段对负荷预测的准确性要求逐渐提高。为满足发展需要, 则要对现有的方法进行改进或建立新的预测方法。通过分析负荷预测数据周期性及周期内的特征, 结合递归神经网络在分析时间序列数据的独特优势和受限玻尔兹曼机的强大的无监督学习能力, 对结合受限玻尔兹曼机的递归神经网络的工作原理及训练过程进行了阐述。利用该网络进行了电力负荷数据预测实验验证并与其他神经网络进行了比较性实验。结果表明, 所提出的神经网络较其他网络在电力短期负荷预测实验中有更高的准确性。

关键词: 负荷预测; 递归神经网络; 受限玻尔兹曼机; 时间序列

Short-term power load forecasting using recurrent neural network with restricted Boltzmann machine

LI Ruochen¹, ZHU Fan², ZHU Yongli³, ZHAI Yujia⁴

(1. State Grid Hebei Power Co., Ltd. Pingshan County Power Supply Branch, Pingshan 050400, China;

2. Philosophy Department, Capital Normal University, Beijing 100037, China;

3. School of Control and Computer Engineering, North China Electric Power University, Baoding 071000, China;

4. Department of Electrical Engineering, North China Electric Power University, Baoding 071000, China)

Abstract: The importance of short-term power load forecasting continues to improve with the development of power enterprises. Although the traditional load forecast has been developed relatively mature, the load forecast accuracy requirements gradually increase now. To meet the development needs, existing methods should be improved or new methods of prediction should be established. This paper analyzes the periodic load forecasting and periodic characteristics of load forecasting data. It also combines recursive neural networks with Limited Boltzmann machine's strong unsupervised learning ability in analyzing the unique advantages of time series data. The network principle and training process of the combination are described and the electric load data are predicted by experiment. The experiment compares the accuracy of the network and other networks in short-term load forecasting. The results show that the neural network proposed in this paper is more accurate than other networks in the power short-term load prediction experiment.

This work is supported by National Natural Science Foundation of China (No. 51677072).

Key words: power load forecasting; recurrent neural network; restricted Boltzmann machine; time series

0 引言

准确的电力系统负荷预测可用于指导和确定发电机组的启停, 水电、火电及其他发电设备之间的相互协调配合与经济发电以及电网设备的计划检修等。短期电力负荷预测主要用来预测未来几小时、

一天或几天的负荷, 它是电力转运业务、电力系统安全的基础, 也牵扯到各电网公司之间的功率交换, 可以给电网带来巨大的效益。

常用的负荷预测方法有很多, 例如灰色系统、专家系统、回归分析法等方法。灰色系统方法是利用众多影响因子的综合作用来分析数据, 文献[1]针对气温对电力负荷影响最大的特点, 通过气象修正的方法将预测误差降低, 但仍然有些负荷数据与气

象数据之间的关系不明显。通过观察数据也可发现, 电力负荷数据并不完全随气温变化, 有时有超前或延后的现象出现, 则需要进一步研究其关系。专家系统的方法则是依据往年电力负荷数据以及行业专家经验建立规则与知识库, 推理机利用目前的电力负荷数据进行推进性预测。文献[2]通过对各影响因素模糊化, 建立模糊集、隶属度函数和模糊规则的专家系统来弥补数据预测不准确带来的缺陷。这两种方法虽然已经考虑到了多种因素, 例如气候、温度以及政策等, 然而其他因素仍然不可忽略地会影响电力负荷。回归分析利用比较简单的数理统计方法来确定数据之间的关系, 属于经典预测方法。由于影响电力负荷因素较多, 现阶段较少使用简单的回归分析对电力系统负荷数据进行预测。

近些年来机器学习的方法在电力系统负荷预测中的应用越来越广泛, 例如支持向量机(SVM)、人工神经网络和深度学习的方法。SVM的预测方法是根据时间序列数据, 通过一个非线性的映射将输入空间的数据映射到高维空间并在高维空间进行分类, 从而建立输入与输出数据之间的关系, 文献[3]利用遗传算法对SVM进行了优化, 并应用于风电功率预测, 有较好的效果。传统神经网络由于网络学习速率慢, 容易陷入局部最优且易震荡的问题, 使得这些神经网络存在严重的局限性。文献[4-10]利用人工神经网络并根据相应的负荷数据特点利用遗传算法、模拟退火算法以及单步预测代替多步预测等方法对传统神经网络进行改进, 克服了其相应的不足, 且都在电力负荷数据预测之中有着不错的表现。深度学习方法^[11]因其具有较强的特征提取能力在近年来迅速发展起来, 它通过增加网络层数打破了传统神经网络易陷入局部最优的问题, 常见的深度学习模型有: 深层受限玻尔兹曼机^[12-13]、深度信念网络^[14-17]、深度自编码网络等, 随着网络层数的增加, 网络对数据的特征的捕捉能力也得到了相应的增加, 但相应的训练时间也大大增长。人工智能的方法可以很好地统筹电力负荷中的各项影响因子以及其中隐性的因素, 减小负荷预测之中各因子对准确性的影响, 非常适合应用于电力负荷预测之中。

时间序列预测法可以用于短期、中期以及长期预测。根据待预测数据的不同特征又可对数据进行加权、移动等。文献[18]通过构造不同时间尺度的多维数据序列, 很好地提高了预测的精度。而随着神经网络的发展, 拥有关联层的网络的出现使得神经网络具有动态记忆性, 更适合对时间序列数据进

行预测, 如RNN、Elman神经网络^[19]等。

针对现有负荷预测方法的不足, 本文结合受限玻尔兹曼机的强大的无监督学习能力与递归神经网络在解决时间序列问题的独特优势, 提出采用两种网络相结合的方法进行短期负荷预测。该方法既可通过受限玻尔兹曼机把握电力负荷数据高维特征又可以很好地通过递归神经网络做预测, 将其应用于短期电力负荷预测, 起到了很好的效果。

1 结合受限玻尔兹曼机的递归神经网络原理及结构

1.1 数据分析及网络结构

电力负荷数据是一组时间序列数据, 且具有明显的周期性, 受季节、气候、政策等多方面的影响。通过把握数据的明显周期性特征, 既可以很好地将很长的时间序列数据分段处理, 又可以很好地把握每一段数据的特征, 这样就可以增加网络的运行效率, 做到更好的数据特征的提取。因此, 通过对电力负荷数据及其影响因素的分析, 本文采用递归神经网络(Recurrent Neural Network, RNN)的结构使其更好地把握时间序列特征, 并结合受限玻尔兹曼机(Restricted Boltzmann Machines, RBM)把握周期内数据的特征, 包括居民用电规律, 天气、气温等因素对数据的影响。

受限玻尔兹曼机是一种无自反馈网络的随机神经网络, 层内无连接, 层间全连接。由于网络的强大的无监督学习能力, 可将高维的数据很好地降维处理, 可更好地抽象数据特征。因此可通过RBM充分学习周期内的数据特征, 从而更好地将数据降维, 方便数据的预测。

循环神经网络是多层感知器网络的一种改进网络, 由输入层(input layer)、隐藏层(hidden layer)、输出层(output layer)组成, 且隐藏层会连接到下一时刻隐藏层, 由于时间序列数据本身带有特征, 通过网络的反馈就可以很好地把握时间序列数据的网络, 因此通常被称为反馈网络, 即式(1)。

$$h_t = \phi(Wv_t + Uh_{t-1}) \quad (1)$$

式中: h_t 为隐含层状态; t 时刻输入数据为 v_t ; W 为权值; U 为隐藏状态矩阵。

结合受限玻尔兹曼机的递归神经网络由单层的受限玻尔兹曼机(RBM)和一个单层的递归神经网络(RNN)的递归层组成, 加入上下层(context layer), 使两个网络可以发挥其各自的优势, 对数据进行更好的预测, 其结构图如图1所示。

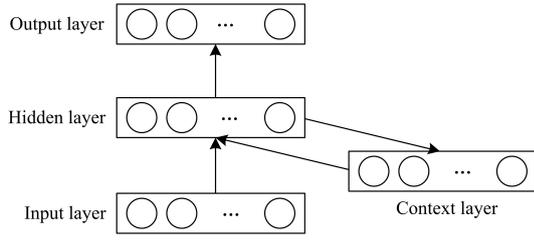


图1 网络结构图

Fig. 1 Structure of network

反馈回路在 RBM 网络的隐藏层位置, 负责通过上一时刻隐含层数据的输入预测下一时刻网络各节点数据, 则可以将网络根据时间展开得到如图 2 所示。

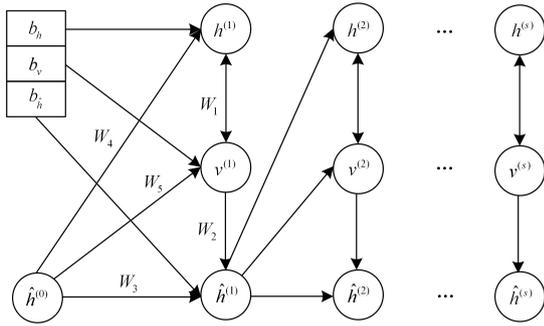


图2 网络时间展开图

Fig. 2 Expansion diagram of network time

图中的 h 表示 RBM 稳态时的节点状态数据, 而 \hat{h} 表示上下层节点中存放的状态数据, W_1 表示 RBM 网络输入层到隐含层的权值, W_2 表示输入层节点 v 到上下层节点的权值, W_3 表示上下层节点到下一时刻上下层节点的权值, W_4 、 W_5 则为上下层节点到 RBM 的隐含层和输入层的权值。

1.2 学习算法

网络的训练用于训练网络中的 8 个参数, 分别为 W_1 、 W_2 、 W_3 、 W_4 、 W_5 5 个网络权值以及网络的三个偏置参数 b_v (可见层节点偏置)、 b_h (隐含层节点偏置)、 $b_{\hat{h}}$ (背景层节点偏置)(图 2 中 8 个参数)。

首先需要将数据全部通过标准化处理到(0,1)内的数据后如式(2)所示。

$$x^{(0)} = \{x^{(0)}(i) | i=1, 2, 3, \dots, N\} \quad (2)$$

并通过随机函数随机网络初始权值 W_1 — W_5 , 然后根据式(3)计算 \hat{h} 。

$$\hat{h}^{(t)} = \sigma(W_2 v^{(t)} + W_3 \hat{h}^{(t-1)} + b_{\hat{h}}) \quad (3)$$

式中: t 为时间; σ 为 sigmoid 函数。

接下来通过式(4)和式(5)计算得到 b_h 和 b_v 。

$$b_h^{(t)} = b_h + W_4 \hat{h}^{(t-1)} \quad (4)$$

$$b_v^{(t)} = b_v + W_5 \hat{h}^{(t-1)} \quad (5)$$

然后进行 RBM 的学习, RBM 作为一种随机网络, 引入概率分布函数及能量函数, 其所具有的能量函数定义为式(6)所示。

$$E(v, h | \theta) = \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j \quad (6)$$

式中, $\theta = \{w_{ij}, a_i, b_j\}$, w_{ij} 为可见层节点 i 与隐含层节点 j 之间的权值, a_i 为可见层偏置, b_j 为隐含层偏置。联合概率分布函数则为式(7)所示。

$$p(v, h | \theta) = \frac{e^{-E(v, h | \theta)}}{Z(\theta)} \quad (7)$$

式中, $Z(\theta)$ 为分配函数, 如式(8)所示。

$$Z(\theta) = \sum_{v, h} e^{-E(v, h | \theta)} \quad (8)$$

由于 RBM 网络的特点, 隐含层各节点的节点状态是彼此条件独立的, 则第 j 个隐含层节点的激活概率为式(9)。

$$p(h_j = 1 | v, \theta) = \sigma(b_j + \sum_i W_{ij} v_i) \quad (9)$$

第 i 个可见层节点的激活概率则为式(10)。

$$p(v_i = 1 | h, \theta) = \sigma(a_i + \sum_j W_{ij} h_j) \quad (10)$$

由于最终目的是求参数 θ , 则需要最大化 RBM 在训练集上的对数似然函数, 求 $\log P(v^{(t)} | \theta)$ 关于 θ 的偏导, 即式(11)。

$$\frac{\partial \log P(v | \theta)}{\partial \theta} = \frac{\sum_{t=1}^T \frac{\partial (-E(v^{(t)}, h | \theta))}{\partial \theta}}{\sum_{t=1}^T \frac{\partial (-E(v, h | \theta))}{\partial \theta}} \quad (11)$$

本文网络中的 RBM 也是按照上述方法对网络进行训练, 首先通过 k 次 gibbs 采样从 0-1 化后的数据 $x^{(0)}$, 转化为 RBM 的可见层输入数据如(12)所示。

$$v^{(0)} = \{v^{(0)}(i) | i=1, 2, 3, \dots, N\} \quad (12)$$

则根据 RBM 的能量公式, 网络的自由能量公式为式(13)。

$$F(v) = -b_v^T v - \sum_i \log(1 + e^{b_h + w_i v_i}) \quad (13)$$

根据 RBM 中联合概率分布函数, 本文网络的代价函数则可以写成式(14)。

$$p(v) = \frac{e^{-F(v)}}{Z} \quad (14)$$

然后只需根据 SGD (Stochastic Gradient Descent) 算法对每个分量求偏导(即对 θ 求偏导), 求出模型中各个参数即可。

2 结合受限玻尔兹曼机的递归神经网络电力负荷预测原理

2.1 训练样本的选取

由于电力负荷数据受多方面的影响且不可能将其一一考虑入内,则需要选择对其影响较大的特征数据,经过大量文献证明,气温对电力负荷数据的影响最大,另外电力数据也随天气变化产生一定的波动。

结合受限玻尔兹曼机的递归神经网络电力负荷预测是根据往期电力负荷数据并综合天气、气温数据,通过网络预测后一天电力负荷数据。

2.2 网络的输入及输出

考虑天气数据无法量化,则需要给天气数据进行编码。将天气数据进行编码,晴、阴、雨、雪分别编码为 0.2、0.4、0.6、0.8。然后将所有数据进行标准化处理,将数据统一到 0-1 之间。

网络的输入层节点输入数据及输出层输出数据分别如图 3 所示。

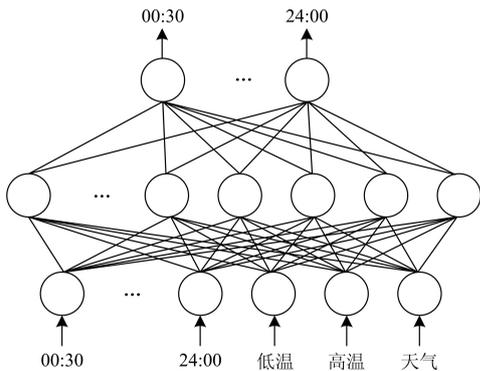


图 3 网络负荷预测模型

Fig. 3 Load forecasting model of network

其中上下层(context layer)未在图中表现,图中时间表示当时刻负荷预测数据,低温和高温表示当天最高和最低气温,天气表示天气编码后的数据。

2.3 负荷预测步骤

负荷预测方法实现过程如下:

(1) 选取样本数据及特征变量,对数据进行标准化处理,并将其分为训练集和测试集;

(2) 建立基于受限玻尔兹曼机的神经网络负荷预测模型;

(3) 使用训练集数据对网络进行训练,并通过大量实验找到相对较优的训练次数(epochs)和学习速率;

(4) 使用训练集数据并应用上步得出的训练次数和学习速率训练网络;

(5) 使用测试集数据生成预测数据,并做出折线图。

3 实验及分析

本文采用 python 编写网络,网络分为训练模式和生成模式,训练模式根据训练集数据训练网络参数,得到最优权值及偏置矩阵,然后生成模式利用前一天负荷、温度等数据生成后一天网络数据,并生成折线图。

本文使用的数据来自欧洲电网某城市 1998 年全民用电负荷数据,气温、天气数据来自该城市气象局发布数据,部分数据如表 1 所示。

表 1 居民用电负荷数据(单位 MV)

Table 1 Household electricity load data (unit MV)

日期	0:30	...	24:00	气温	天气
1.1	728	...	659	(1, 7)	晴
1.2	668	...	663	(2, 7)	阴
1.3	679	...	637	(1, 6)	晴
1.4	662	...	636	(2, 7)	晴
1.5	653	...	637	(2, 7)	晴
1.6	656	...	635	(3, 8)	晴
1.7	631	...	657	(2, 7)	晴
⋮	⋮	⋮	⋮	⋮	⋮
12.25	712	...	695	(5, 9)	晴
12.26	703	...	679	(5, 9)	晴
12.27	711	...	665	(5, 8)	晴
12.28	682	...	688	(5, 8)	晴
12.29	709	...	678	(5, 8)	阴
12.30	697	...	700	(3, 8)	阴
12.31	716	...	733	(3, 8)	阴

在网络训练次数(epochs)和学习速率(learning rate)方面,本文通过大量实验比较了不同训练次数和学习速率之下相对于原始数据的均方差,以此来确定最佳训练次数以及更好的准确性,数据大致如表 2 所示,表中只呈现几组代表性数据。

表 2 训练次数与学习速率

Table 2 Training epochs and learning rate

训练次数	学习速率	均方差
500	0.01	13 584.762 1
1 000	0.01	5 226.587 1
1 500	0.02	2 514.633 4
2 000	0.02	1 241.859 3
2 500	0.02	993.562 8
2 000	0.03	992.987 7
2 000	0.04	1 391.813 4

经过大量的实验结果证明,当训练次数达到 2 000 次且学习速率在 0.03 时预测结果已经达到相对最优的数据,当训练次数达到 2 000 次以上时,

负荷预测的准确性并没有明显的增加。随着训练次数的增加, 网络的训练时间也会相应地增加。因此对于本文使用的负荷数据, 将训练次数确定为 2 000 次。

为了检验本网络的准确性, 本文通过实验用相同数据通过 BP 神经网络对 12 月 21 日电力负荷进行预测, 并将两个数据同原负荷数据一并通过折线图的方式进行了分析, 通过计算均方差验证实验结果, 如图 4 所示。

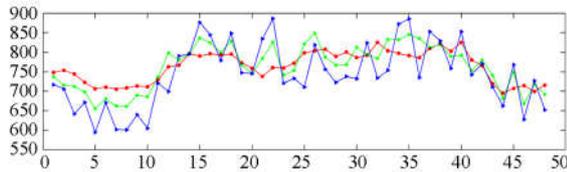


图 4 负荷预测结果对比图

Fig. 4 Comparison of load forecast results

图中数据分别为原始 12 月 21 日全天电力负荷数据(由红色圆点表示)和 BP 神经网络对电力负荷数据的预测结果(由蓝色三角形表示)以及本文网络对其整日电力负荷预测的结果(由绿色星号表示)。纵坐标为用电量(单位 MW), 横坐标 1-48 表示时间 0:30—24:00。从图中并通过分别计算预测精度评价指标均方差(MSE)以及平均绝对百分误差(MAPE), 对实验结果进行了分析。MSE 和 MAPE 计算公式如式(15)、式(16)所示。

$$MSE = \frac{\sum e^2}{n-1} = \frac{\sum (x-x')^2}{n-1} \quad (15)$$

$$MAPE = \frac{1}{n} \sum \left| \frac{x-x'}{x} \right| \quad (16)$$

除比较了 BP 神经网络外, 还应用递归神经网络进行了预测实验, 结果如表 3 所示。

表 3 实验结果对比

Table 3 Comparison of experimental results

训练次数	MSE	MAPE
BP 神经网络	3 929.357 6	0.071 0
RNN 神经网络	1 786.401 0	0.050 2
本文网络	972.300 4	0.035 6

从表中对比可以看出, 本文应用的网络有更好的精度, 更加适合于电力负荷预测。

4 结论

本文网络充分利用了受限玻尔兹曼机以及递归神经网络各自的优势, 数据通过受限玻尔兹曼机进行降维处理后, 提高了递归神经网络对数据预测的

准确性, 弥补了 RNN 和 RBM 在数据预测方面的不足, 使其更加具有针对性, 且网络结构简单, 训练速度较快。实验证明网络的特殊结构使其更适用于短期电力负荷预测, 可以很好地提高短期电力负荷预测的准确性, 且对于类似具有周期性特征的数据预测具有一定的优势。通过对短期电力负荷预测准确性的提高, 更准确地把握未来几小时以及一天之内的负荷数据, 对短期内合理的电力调度有很好的现实意义。

参考文献

- [1] 焦润海, 苏辰隽, 林碧英, 等. 基于气象信息因素修正的灰色短期负荷预测模型[J]. 电网技术, 2013, 37(3): 720-725.
JIAO Runhai, SU Chenjun, LIN Biying, et al. Short-term load forecasting by grey model with weather factor-based correction[J]. Power System Technology, 2013, 37(3): 720-725.
- [2] 段杰, 王秀丽, 侯雨伸. 基于模糊专家系统的输电线路分段冰风荷载等效停运率模型[J]. 电工技术学报, 2016, 31(8): 220-228.
DUAN Jie, WANG Xiuli, HU Yushen. Piecewise equivalent model of ice disaster impact on outage rate of transmission lines using fuzzy expert system[J]. Transactions of China Electrotechnical Society, 2016, 31(8): 220-228.
- [3] 刘爱国, 薛云涛, 胡江鹭, 等. 基于 GA 优化 SVM 的风电功率的超短期预测[J]. 电力系统保护与控制, 2015, 43(2): 90-95.
LIU Aiguo, XUE Yuntao, HU Jianglu, et al. Ultra-short-term wind power forecasting based on SVM optimized by GA[J]. Power System Protection and Control, 2015, 43(2): 90-95.
- [4] 李龙, 魏靖, 黎灿兵, 等. 基于人工神经网络的负荷模型预测[J]. 电工技术学报, 2015, 30(8): 225-230.
LI Long, WEI Jing, LI Canbing, et al. Prediction of load model based on artificial neural network[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 225-230.
- [5] 王新普, 周想凌, 邢杰, 等. 一种基于改进灰色 BP 神经网络组合的光伏出力预测方法[J]. 电力系统保护与控制, 2016, 44(18): 81-87.
WANG Xinpu, ZHOU Xiangling, XING Jie, et al. A prediction method of PV output power based on the combination of improved grey back propagation neural network[J]. Power System Protection and Control, 2016, 44(18): 81-87.
- [6] 李龙, 魏靖, 黎灿兵, 等. 基于人工神经网络的负荷模型预测[J]. 电工技术学报, 2015, 30(8): 225-230.
LI Long, WEI Jing, LI Canbing, et al. Prediction of load

model based on artificial neural network[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 225-230.

[7] 陈昌松, 段善旭, 殷进军. 基于神经网络的光伏阵列发电预测模型的设计[J]. 电工技术学报, 2009, 24(9): 153-158.
CHEN Changsong, DUAN Shanxu, YIN Jinjun. Design of photovoltaic array power forecasting model based on neural network[J]. Transactions of China Electrotechnical Society, 2009, 24(9): 153-158.

[8] 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.
CHENG Yuye. Short-term electricity demand forecasting based on artificial neural network[D]. Hangzhou: Zhejiang University, 2017.

[9] 张程熠, 唐雅洁, 李永杰, 等. 适用于小样本的神经网络光伏预测方法[J]. 电力自动化设备, 2017, 37(1): 101-106, 111.
ZHANG Chengyi, TANG Yajie, LI Yongjie, et al. Photovoltaic power forecast based on neural network with a small number of samples[J]. Electric Power Automation Equipment, 2017, 37(1): 101-106, 111.

[10] 李鹏鹏, 彭显刚, 孟安波, 等. 小波贝叶斯神经网络在冲击负荷地区短期负荷预测中的应用[J]. 电力科学与工程, 2012, 28(11): 7-12.
LI Pengpeng, PENG Xiangang, MENG Anbo, et al. Application of wavelet Bayesian neural network in short term load forecasting of impact load area[J]. Power Science and Engineering, 2012, 28(11): 7-12.

[11] 余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804.
YU Kai, JIA Lei, CHEN Yuqiang, et al. Deep learning: yesterday, today, and tomorrow[J]. Journal of Computer Research and Development, 2013, 50(9): 1799-1804.

[12] HINTON G E. A practical guide to training restricted Boltzmann machines[R]. Toronto, Canada: University of Toronto, 2010.

[13] 张春霞, 姬楠楠, 王冠伟. 受限波尔兹曼机[J]. 工程数学学报, 2015, 32(2): 159-173.
ZHANG Chunxia, JI Nannan, WANG Guanwei. Restricted Boltzmann machines[J]. Chinese Journal of Engineering Mathematics, 2015, 32(2): 159-173.

[14] 唐智灵, 吕晓朦. 基于改进的深度置信网络的电离层F2层临界频率预测[J]. 计算机应用研究, 2018, 35(3): 1-2.
TANG Zhiling, LÜ Xiaomeng. Ionosphere F2 layer critical frequency predict based on improved deep belief networks[J]. Application Research of Computers, 2018, 35(3): 1-2.

[15] 石鑫, 朱永利, 萨初日拉, 等. 基于深度信念网络的电力变压器故障分类建模[J]. 电力系统保护与控制, 2016, 44(1): 71-76.
SHI Xin, ZHU Yongli, SA Churila, et al. Power transformer fault classifying model based on deep belief network[J]. Power System Protection and Control, 2016, 44(1): 71-76.

[16] 马勇, 鲍长春, 夏丙寅. 基于判别性深度信念网络的说话人分割[J]. 清华大学学报(自然科学版), 2013, 53(6): 804-807.
MA Yong, BAO Changchun, XIA Bingyin. Speaker segmentation based on discriminative deep belief networks[J]. Journal of Tsinghua University (Science and Technology), 2013, 53(6): 804-807.

[17] MOHAMED A, DAHL G E, HINTON G. Acoustic modeling using deep belief networks[J]. IEEE Transactions on Audio Speech and Language Processing, 2012, 20(1): 14-22.

[18] 黄磊, 舒杰, 姜桂秀, 等. 基于多维时间序列局部支持向量回归的微网光伏发电预测[J]. 电力系统自动化, 2014, 38(5): 19-24.
HUANG Lei, SHU Jie, JIANG Guixiu, et al. Photovoltaic generation forecast based on multidimensional time-series and local support vector regression in microgrids[J]. Automation of Electric Power Systems, 2014, 38(5): 19-24.

[19] 王晓霞, 马良玉, 王兵树, 等. 进化Elman神经网络在实时数据预测中的应用[J]. 电力自动化设备, 2011, 31(12): 77-81.
WANG Xiaoxia, MA Liangyu, WANG Bingshu, et al. Application of evolutionary Elman neural network in real-time data forecasting[J]. Electric Power Automation Equipment, 2011, 31(12): 77-81.

收稿日期: 2017-08-21; 修回日期: 2017-10-30

作者简介:

李若晨(1991—), 男, 通信作者, 硕士研究生, 研究方向为人工智能在电力系统中的应用; E-mail: 573728717@qq.com

朱帆(1989—), 男, 硕士研究生, 研究方向为现代逻辑与人工智能;

朱永利(1963—), 男, 教授, 博士生导师, 研究方向为网络化监控与智能信息处理。

(编辑 葛艳娜)