

DOI:10.3969/j.issn.1001-4551.2015.09.018

智能用电环境下电力负荷预测方法的研究*

马立新,尹晶晶,郑晓栋,栾 健
(上海理工大学 光电信息与计算机工程学院,上海 200093)

摘要:针对在智能用电环境下研究对象复杂且负荷随机性强,短期电力负荷预测算法精度差、计算时间长等问题,提出一种基于 ELM-Adaboost 神经网络改进算法预测短期电力负荷的新方法。该方法引入 Adaboost 算法,首先对经过预处理后的历史数据进行测试样本权重初始化,然后反复训练 ELM 网络预测输出,ELM 算法预测过程简洁,速度快;通过 Adaboost 算法调整测试样本权重并确定弱预测器权重,最后将得到的多个 ELM 弱预测器组成强预测器。实验以某市的电力负荷数据的进行预测仿真以及结果比较。仿真结果表明该方法具有较高的预测精度,泛化性能好,具有一定的理论意义和较好的应用前景。

关键词:负荷预测;极限学习机;Adaboost 算法;强预测器;神经网络

中图分类号:TM714;TP183

文献标志码:A

文章编号:1001-4551(2015)09-1233-05

Power load forecasting method in smart electricity consumption environment

MA Li-xin, YIN Jing-jing, ZHENG Xiao-dong, LUAN Jian
(School of Optical-Electrical and Computer Engineering, University of Shanghai for
Science and Technology, Shanghai 200093, China)

Abstract: Aiming at solving the problems that the research objects are complex, the load randomness is strong and the short-term power load forecasting has low forecasting accuracy and long computation time in smart electricity consumption environment, a new power load forecasting method that based on extreme learning machine (ELM) and Adaboost algorithm was proposed. The Adaboost algorithm was extended to this method. Firstly, the historical data were processed, the sample weights were initialized and the ELM network was trained repeatedly to predict output data. The forecasting process of ELM was simple and fast. The weight of weak predictors was identified through the Adaboost algorithm adjusting the weight of test samples. Finally the weak predictors were assembled together to constitute a strong predictor. The power load data of one city were used for simulating and comparing. The results indicate that this method not only has high prediction precision and good generalization performance, but also has a certain theoretical significance and good application prospect.

Key words: load forecasting; extreme learning machine; adaboost algorithm; strong predictor; neural network

0 引 言

智能用电环境下电力负荷预测的研究对象包括工业、商业和居民用户,研究对象复杂且用户侧的随机性强,因而总体的预测结果不是很理想^[1]。人工神经网络^[2]目前已广泛的应用于电力负荷预测领域,但是传统的神经网络如 BP 神经网络存在收敛速度比较慢,

以及容易陷入局部极小值等问题^[3]。极限学习机 ELM(Extreme Learning Machine)是近年来提出的一种新的单隐层前馈神经网络 SLFNs(Single hidden Layer Feed forward Networks)学习算法^[4-5]。在网络训练的过程中,输入层的权值和隐层的阈值是随机给定的,与传统的神经网络相比,ELM 具有学习速度快,泛化性能好的优点^[6]。但 ELM 随机设置输入层的权值和隐

收稿日期:2015-03-26

基金项目:国家自然科学基金资助项目(61205076);上海市张江国家自主创新重点资助项目(201310-PI-B2-008)

作者简介:马立新(1960-),男,陕西安康人,工学博士,教授,主要从事电力系统分析与优化运行,智能电网与智能科学,电气设备状态监测与诊断方法,电能质量监控与能效测评技术,风光发电智能控制系统方面的研究。E-mail:malx_aili@sina.com

层的阈值,这就很可能会产生输出层权值不是最优的,从而使经过学习后得到的前馈网络也不是最优的,会导致隐层需要更多的单元,从而会使网络变得复杂,影响其测试的响应速度。

针对以上问题,目前已有部分文献对 ELM 方法做出了改进。文献[7]通过降低网络隐含层输出矩阵条件数来优选输入层权重,该算法能够保持隐含层输出矩阵条件数为最优,但该算法仅适应于线性隐单元极限学习机。文献[8]运用粒子群算法优化 ELM 网络的输入层权重和隐含层阈值,但是粒子群算法搜索精度不够,对高维函数的优化性能不佳。文献[9]提出了一种基于时间序列编码相似日选择和 ELM 相结合的负荷预测方法;此方法计算量较大,运行时间较长。文献[10]引入基于结构风险最小化理论,并结合最小二乘向量机回归学习方法,以克服传统极限学习机在短期负荷预测中存在的过拟合问题,但负荷预测误差较大。

要提高预测精度,不仅需要构建的模型泛化能力强,同时还需要训练样本模型构建的合适。为此提出用 Adaboost 算法改进 ELM 算法为强预测算法,来解决目前在智能用电环境下预测算法精度不高以及运行时间长的情况。该方法首先对经过预处理后的历史数据进行测试样本权重初始化,然后反复训练 ELM 预测输出;通过 AdaBoost 算法调整测试样本权重并确定弱预测器权重,最后将得到的多个 ELM 弱预测器组成强预测器。经算例分析,基于 Adaboost 的 ELM 算法(下文称为 ELM-AdaBoost)在短期电力负荷预测中的精度较高。

1 极限学习机

ELM 是一种单隐层前馈神经网络 SLFNs 通过训练新算法发展而来的^[11-12]。




图 1 单隐层前馈神经网络结构

设有 N 个不同的任意样本 $(\boldsymbol{x}_i, \boldsymbol{t}_i)$, $\boldsymbol{x}_i$ 和 $\boldsymbol{t}_i$ 分别表示输入向量与输出向量,其中 $\boldsymbol{x}_i = [x_{i1}, x_{i2}, \cdots, x_{im}]^T \in R^n$, $\boldsymbol{t}_i = [t_{i1}, t_{i2}, \cdots, t_{im}]^T \in R^m$ 具有 $\tilde{N}$ 个单隐层结点, $g(x)$ 是激活函数,它的标准 SLFNs 模型表示为:

$$\sum_{i=1}^{\tilde{N}} \boldsymbol{\beta}_i g_i(\boldsymbol{x}_j) = \sum_{i=1}^{\tilde{N}} \boldsymbol{\beta}_i g_i(\boldsymbol{a}_i \cdot \boldsymbol{x}_j + \boldsymbol{b}_i) \quad j = 1, \cdots, N \quad (1)$$

式中: $\boldsymbol{a}_i = [a_{i1}, a_{i2}, \cdots, a_{im}]^T$ —隐层第 i 个结点与输入层的连接权向量(Weight Vector); $\boldsymbol{b}_i$ —隐层第 i 个结点与输入层的阈值(Bias); $\boldsymbol{\beta}_i$ —第 i 个隐层与输出层的输出权向量, $\boldsymbol{\beta}_i = [\beta_{i1}, \beta_{i2}, \cdots, \beta_{im}]^T$; $\boldsymbol{a}_i \cdot \boldsymbol{x}_j$ —向量 $\boldsymbol{a}_i$ 和 $\boldsymbol{x}_j$ 的内积。

激活函数 $g(x)$ 可以选择“sigmoid”, “sine”或者“RBF”等。

含有 $\tilde{N}$ 个隐层节点的激活函数 $g(x)$ 的标准 SLFNs 能够以零误差逼近 N 个训练样本,并存在 $\boldsymbol{\beta}$ 和 $\boldsymbol{x}_j$ 使得:

$$\sum_{i=1}^{\tilde{N}} \boldsymbol{\beta}_i g_i(\boldsymbol{a}_i \cdot \boldsymbol{x}_j + \boldsymbol{b}_i) = \boldsymbol{t}_j, j = 1, \cdots, N \quad (2)$$

式(2)写成矩阵形式为:

$$\boldsymbol{\beta} \boldsymbol{H} = \boldsymbol{T} \quad (3)$$

式中: $\boldsymbol{H}$ —网络的隐含层输出矩阵。

ELM 算法中,输入层连接权重和阈值是随机给定的,隐含层矩阵 $\boldsymbol{H}$ 是一个确定的矩阵,因此训练 SLFNs 就可以就转化为一个求最小二乘解的问题,使得 $\boldsymbol{\beta} \boldsymbol{H} = \boldsymbol{T}$,即:

$$\hat{\boldsymbol{\beta}} = \min_{\boldsymbol{\beta}} \| \boldsymbol{T}(\boldsymbol{a}_1, \cdots, \boldsymbol{a}_{\tilde{N}}, \boldsymbol{b}_1, \cdots, \boldsymbol{b}_{\tilde{N}}) \boldsymbol{\beta} - \boldsymbol{T} \| \quad (4)$$

式(4)可以表示为:

$$\hat{\boldsymbol{\beta}} = \boldsymbol{H}^+ \boldsymbol{T} \quad (5)$$

式中: $\boldsymbol{H}^+$ —隐含层输出矩阵 $\boldsymbol{H}$ 的 Moore-Penrose 广义逆。

2 Adaboost 算法

Adaboost 算法^[13]是机器学习中一种重要的特征分类算法,在交通量预测以及税收预测中都有用到,预测精度比较高。Adaboost 是一种迭代算法,Adaboost 算法首先对同一样本训练集训练不同的弱预测器,然后将这些弱预测器集合起来,构成一个强预测器,来提高预测算法的泛化能力以及精度。

其核心思想是重视预测误差大的样本和性能好的弱学习器,即提高训练集中训练效果差的样本权值和学习能力强的弱学习器权值,降低训练效果好的样本权值和学习能力弱的弱学习器权值^[14]。

Adaboost 算法详细步骤:

(1)对样本训练集进行初始化: $S = \{(\boldsymbol{X}, \boldsymbol{Y}) | \boldsymbol{X} \in R^n, \boldsymbol{Y} \in R^m, i = 1, \cdots, N\}$, $\boldsymbol{X}$ 和 $\boldsymbol{Y}$ 分别表示输入和输出数据;初始化时,训练样本进行归一化处理,使样本值分布在 $[0, 1]$ 区间。

(2)将训练集平均分为 N 个训练样本,每个训练样本的权值相同,分别为 $D_i(i)$, $D_i(i) = 1/N$ 。

- (3)训练弱预测器 $h_i(x)$ 。
- (4)网络学习结束后,计算该弱预测器在各样本下的训练误差 ε_i 和平均误差 $\varepsilon_i = \sum_{i=1}^N \varepsilon_i / N$ 。
- (5)更新每个弱预测器的权重 $D_i(i) = D_{i-1}(i) \beta_i^{-\varepsilon_i} / Z_i$,修改每个样本的权重 $W_i = \ln(1/\beta_i)/2$;其中 $\beta_i = \varepsilon_i / (1 - \varepsilon_i)$, Z_i 是使 $\sum_{i=1}^N D_i(x_i) = 1$ 的归一化因子。
- (6)转移到第(3)步,继续进行迭代计算,当迭代次数为 T 的时候就结束。
- (7)采用训练产生的弱预测器来构成强预测器 $H(x) = \sum_{i=1}^N W_i h_i(x)$ 。

3 ELM-Adaboost 改进算法

ELM-AdaBoost 改进算法的预测模型如图 2 所示。




图 2 ELM-Adaboost 预测模型

ELM-AdaBoost 改进算法流程如图 3 所示。

4 算例分析

本研究预测误差评价标准为绝对误差 (APE)、平均绝对误差 (MAPE)^[15] 以及最大绝对误差 (Max_APE),具体定义为:

$$APE = \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \tag{6}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \tag{7}$$




图 3 ELM-Adaboost 算法流程

$$Max_APE = \text{Max} \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \right) \tag{8}$$

式中: y_i —真实值; $\hat{y}_i$ —预测输出值; n —负荷数据点组成,这里 $n = 24$ 。

本研究以某市 2012 年 1 月到 12 月的历史电力负荷作为实验数据,每 1 h 一个采样点,每天 24 个点,采用 ELM-Adaboost 模型进行预测。将本研究方法预测结果与 BP 神经网络算法、ELM 算法的预测结果进行对比。其中 ELM 算法使用 sigmoid 函数作为算法的激励函数,并使用交叉验证法选择隐含层节点数。BP 神经网络的学习速率为 0.1,为了方便与 ELM 算法进行比较,设置 BP 网络的隐含层节点数与 ELM 的相同。

实验一:选取 11 月 1 日到 11 月 30 日中 24 个时刻的历史负荷数据作为训练样本,来预测 12 月 1 日 24 个不同时刻的负荷。结果如表 1 所示。

表 1 负荷预测误差分析 (单位:MW)

时刻	实际值	BP		ELM		ELM-Adaboost	
		预测值	APE/%	预测值	APE/%	预测值	APE/%
0	1 019.9	1 026.5	0.65	997.1	2.24	1 007.5	1.22
1	1 024.0	1014.3	0.95	998.3	2.51	1 012.6	1.12
2	1 016.2	1004.2	1.17	987.1	2.86	1 001.2	1.47
3	983.4	994.9	1.17	973.2	1.03	985.8	0.24
4	975.5	985.4	1.02	965.9	0.98	976.8	0.14
5	984.8	1 000.2	1.57	970.3	1.47	981.0	0.38
6	994.7	1 019.9	2.53	990.0	0.47	996.4	0.17
7	1 026.3	1 056.1	2.90	1 032.7	0.62	1 036.7	1.01
8	1 070.8	1 116.4	4.26	1 090.7	1.85	1 085.9	1.41
9	1 147.2	1 203.5	4.91	1 172.7	2.23	1 160.3	1.14
10	1 206.5	1 253.7	3.91	1 212.7	0.51	1 206.9	0.03

(续表)

时刻	实际值	BP		ELM		ELM-Adaboost	
		预测值	<i>APE</i> /%	预测值	<i>APE</i> /%	预测值	<i>APE</i> /%
11	1 166.9	1 218.9	4.45	1 176.4	0.81	1 164.9	0.17
12	1 102.2	1 132.7	2.77	1 105.4	0.29	1 103.9	0.16
13	1 162.3	1 214.3	4.48	1 169.5	0.62	1 155.9	0.55
14	1 182.6	1 228.9	3.92	1 179.3	0.28	1 162.4	1.71
15	1 172.7	1 234.2	5.24	1 182.4	0.82	1 173.9	0.10
16	1 199.8	1 230.7	2.57	1 192.3	0.62	1 181.7	1.50
17	1 173.8	1 201.0	2.32	1 165.0	0.75	1 165.7	0.69
18	1 153.9	1 195.9	3.64	1 173.3	1.68	1 161.6	0.67
19	1 136.3	1 181.0	3.94	1 163.3	2.38	1 157.3	1.85
20	1 118.4	1 148.3	2.67	1 138.2	1.77	1 131.2	1.15
21	1 105.2	1 147.2	3.80	1 128.1	2.07	1 121.2	1.45
22	1 079.6	1 108.4	2.67	1 096.5	1.57	1 092.1	1.16
23	1 017.0	1 054.3	3.67	1 037.6	2.03	1 027.9	1.07
<i>MAPE</i> /%		2.97		1.35		0.86	
<i>Max_APE</i> /%		5.24		2.86		1.85	

不同预测模型的性能比较情况如表 1 所示。由表 1 可以看出,ELM-Adaboost 预测模型的平均绝对误差以及最大绝对误差都最小。与传统 BP 神经网络方法相比,预测精度提高了 2.11%,与 ELM 方法相比,预测精度提高了 0.49%。

实验二:为了验证本研究方法对于夏季负荷预测的有效性,选取 7 月 1 日到 7 月 31 日中 24 个时刻的历史负荷数据作为训练样本,来预测 8 月 1 日 24 个不同时刻的负荷。与实验一的数据相比,实验二每日同时刻数据波动较大。负荷预测结果曲线如图 4 所示,

误差分析如表 2 所示。




图 4 负荷预测结果曲线

表 2 负荷预测误差分析 (单位:MW)

时刻	实际值	BP		ELM		ELM-Adaboost	
		预测值	<i>APE</i> /%	预测值	<i>APE</i> /%	预测值	<i>APE</i> /%
0	1 250.0	1 003.7	1.59	1 219.8	2.42	1 245.1	0.40
1	1 221.5	994.8	2.85	1 202.1	1.59	1 227.8	0.52
2	1 185.8	998.4	1.75	1 181.0	0.40	1 204.6	1.58
3	1 160.9	1 005.1	2.21	1 156.4	0.38	1 174.8	1.20
4	1 143.2	989.7	1.45	1 139.4	0.34	1 153.4	0.89
5	1 140.4	987.5	0.28	1 125.0	1.35	1 139.3	0.09
6	1 137.3	1 008.7	1.41	1 126.4	0.96	1 147.5	0.90
7	1 161.0	1 002.0	2.38	1 149.3	1.00	1 167.4	0.55
8	1 283.6	1 047.7	2.16	1 256.7	2.09	1 268.1	1.20
9	1 416.9	1 094.9	4.56	1 375.7	2.91	1 395.5	1.51
10	1 480.2	1 122.4	6.97	1 440.6	2.68	1 462.3	1.21
11	1 466.5	1 100.2	5.72	1 423.8	2.91	1 450.4	1.10
12	1 427.5	1 023.5	7.14	1 378.4	3.44	1 410.4	1.20
13	1 495.2	1 111.4	4.37	1 448.4	3.13	1 482.9	0.83
14	1 504.5	1 151.9	2.60	1 467.2	2.48	1 499.2	0.36
15	1 495.4	1 137.9	2.97	1 457.4	2.54	1 493.1	0.15
16	1 488.9	1 148.7	4.26	1 443.4	3.06	1 479.5	0.63
17	1 396.4	1 095.7	6.65	1 369.4	1.93	1 404.3	0.57
18	1 318.0	1 123.6	2.62	1 340.3	1.69	1 335.6	1.33
19	1 325.1	1 090.8	4.01	1 342.6	1.32	1 345.6	1.55
20	1 389.3	1 051.6	5.98	1 413.3	1.73	1 410.1	1.50
21	1 393.0	1 058.7	4.21	1 420.9	2.00	1 416.6	1.70

(续表)

时刻	实际值	BP		ELM		ELM-Adaboost	
		预测值	APE/%	预测值	APE/%	预测值	APE/%
22	1 362.7	1 054.4	2.33	1 381.5	1.38	1 377.0	1.05
23	1 303.3	1 002.0	1.48	1 272.1	2.39	1 298.0	0.41
MAPE/%		3.41		1.92		0.93	
Max_APE/%		7.14		3.44		1.70	
运行时间/s		1.589		0.141		0.168	

不同预测模型的性能比较情况如表 2 所示。由此可见,采用基于 Adaboost 的 ELM 网络模型进行日负荷预测的精度比较理想,预测结果平均绝对误差 1% 左右,最大绝对误差为 1.70%。ELM-Adaboost 与 BP 相比,前者比后者的运行时间明显减少,速度更快,预测误差减少 2.48%。ELM-Adaboost 与 ELM 相比,后者比前者的运行时间减少,但平均绝对误差增加0.99%。通过图 4 可以看出,本研究算法与原始曲线很接近。综上可得,ELM-Adaboost 方法能有效提高预测精度,且泛化性能好。

5 结束语

本研究提出使用 Adaboost 算法来改进 ELM 算法,解决目前在智能用电环境下预测算法精度不高计算时间长的问题。Adaboost 算法核心思想是重视预测误差大的样本和性能好的弱预测器,即提高训练集中训练效果差的样本权值和学习能力强的弱预测器权值,降低训练效果好的样本权值和学习能力弱的弱预测器权值。

本研究方法对冬季和夏季某日的负荷分别进行了预测。从算例结果中可以看出,与传统 BP 神经网络相比,在预测精度和预测速度上本研究方法都具有明显的优势,满足了电网公司对负荷预测精度的要求;另外,本研究方法比常用算法具有更好的泛化能力,因此在电力负荷预测中具有很好的应用前景。

参考文献 (References):

[1] 汤庆峰,刘念,张建华. 计及广义需求侧资源的用户侧自动响应机理与关键问题[J]. 电力系统保护与控制, 2014,42(24):138-147.

[2] 孙大帅,马立新,王守征. 基于复杂系统的短期负荷预测研究及系统设计[J]. 上海理工大学学报,2010,33(1):39-43.

[3] 王志勇,郭创新,曹一家. 基于模糊粗糙集和神经网络的

短期负荷预测方法[J]. 中国电机工程学报,2005,25(19):7-11.

[4] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and application[J]. **Neurocomputing**, 2006(70):489-501.

[5] HUANG G B, ZHU Q Y, SIEW C K. Extreme Learning Machine:a new Learning Scheme of Feedforward Neural Networks[C]. in Proc. Int. Joint Conf. Neural Networks (IJCNN2004), Buda-pest, Hungary,2004:985-990.

[6] 王龙,成天乐,陈宇. 基于 EMD 和 ELM 的短期负荷预测[J]. 电力科学与工程,2014,30(6):54-58.

[7] ZHAO G P, SHEN Z Q, MIAO C Y, et al. On Improving the Conditioning of Extreme Learning Machine: A Linear Case[C]. 7th International Conference on Information, Communications and Signal Processing, 2009 (ICICS2009) (Maucu, China), December 8-10,2009:1-5.

[8] YOU Xu, YANG Shu. Evolutionary Extreme Learning Machine-Based on Particle Swarm Optimization[C]. International Symposium on Neural Networks,2006:644-652.

[9] 王伟,杨辉华,刘振丙,等. 基于极限学习机的短期负荷预测[J]. 计算机仿真,2014,31(4):137-141.

[10] 毛力,王运涛,刘兴阳,等. 基于改进极限学习机的短期电力负荷预测方法[J]. 电力系统保护与控制,2012,40(20):140-144.

[11] 黄骏. 基于 Hadoop 的高频电力负荷监测数据存储研究[J]. 机电工程技术,2014(3):33-35,93.

[12] 吴登国,李晓明. 基于极限学习机的配电网重构[J]. 电力自动化设备,2013,33(2):47-56.

[13] MORRA J H, ZHUOWEN T U, Apostolova L G. Comparison of adaboost and support vector machines for detecting Alzheimer's disease through automated hippocampal segmentation[J]. **IEEE Trans on Medical Imaging**,2010,29(1):30-43.

[14] 柳玉,郭虎全. 基于 Adaboost 和 BP 神经网络的风速预测研究[J]. 电网与清洁能源,2012,28(2):80-89.

[15] 陈超,黄国勇,邵宗凯,等. 基于日特征相似日的 PSO-SVM 短期负荷预测[J]. 中国电力,2013,46(7):91-94.

[编辑:洪炜娜]

本文引用格式: