

短期负荷预测神经网络方法比较

李晓波¹, 罗枚², 冯凯¹

(1. 漯河职业技术学院, 河南 漯河 462000; 2. 陕西纺织服装职业技术学院, 陕西 咸阳 712000)

摘要: 以某地区购网有功功率的负荷数据为背景, 建立了三个 BP 神经网络负荷预测模型——SDBP、LMBP 及 BRBP 模型进行短期负荷预测工作, 并对其结果进行比较。针对传统的 BP 算法具有训练速度慢, 易陷入局部最小点的缺点, 采用具有较快收敛速度及稳定性的 L-M 优化算法进行预测, 使平均相对误差有了很大改善, 具有良好的应用前景。而采用贝叶斯正则化算法可以解决网络过度拟合, 提高网络的推广能力, 使平均相对误差和每日峰值相对误差降低, 但收敛速度过慢 (慢于 SDBP 模型), 不适于在实际应用中采用。

关键词: 短期负荷预测; 人工神经网络; L-M 算法; 贝叶斯正则化算法; 优化算法

Comparison of neural network methods for short-term load forecasting

LI Xiao-bo¹, LUO Mei², FENG Kai¹

(1. Luohe Vocational and Technical College, Luohe 462000, China; 2. Shanxi Textile and Garment Institute, Xianyang 712000, China)

Abstract: Based on the load data of meritorious power of the power system of some area, three BP ANN models, named SDBP model, LMBP model and BRBP Model, are established to carry out the short-term load forecasting work, and the results are compared. As for the traditional BP algorithm has some unavoidable disadvantages such as the slow training speed and the feasibility of being plunged into local minimums, an optimized L-M algorithm, which has a quicker training speed and better stability, should be applied to forecast, which can effectively reduce the mean relative error. So it has a good application prospect. In contrast, Bayesian Regularization can overcome the excessive fitting, improve the generalization of an ANN and reduce the mean relative error and the relative error of everyday peak values, it is not suitable for actual application because of its slow training speed (slower than SDBP model).

Key words: short-term load forecasting (STLF); ANN; Levenberg-Marquardt algorithm; Bayesian regularization; optimized algorithms

中图分类号: TP183

文献标识码: A

文章编号: 1003-4897(2007)06-0049-05

0 引言

电力系统负荷预测是实现电力系统安全、经济运行的基础, 尤其是在电力市场条件下, 负荷预测不仅对电力系统操作人员、电力市场规划者、供电者有着重要的作用, 而且对其他的电力市场参与者也显得很重要。当负荷预测的差额造成大量运行成本和利润的损失时, 高精度和快速的负荷预测就成为电力系统可靠运行和电力市场供求平衡的保证, 因此对先进的智能预测方法进行研究是很有必要的。

人工神经网络一经引入电力系统, 负荷预测就成为其应用研究的一个主要领域, 也是到目前为止研究得最多的一个课题。90年代初, Park、Lee、

Peng、Sharkawi 等人^[1~3]先后利用神经网络进行电力系统短期负荷预测, 把预测误差从传统方法的 4.22%降低到 2.06%, 引起负荷预测工作者的高度重视, 再次掀起负荷预测的热潮。它杰出的学习能力、处理输入输出变量间的非线性关系的能力, 使它取得了比传统负荷预测更好的效果, 精度提高了许多。

但是, 用 ANN 进行短期负荷预测也有它本身的致命缺点: ①收敛速度慢、容易陷入局部极小点; ②需要大量的训练数据。另外, 它还在学习过程中训练精度不确定性的问题。为了克服 ANN 的这些缺点, 提高各类日期的负荷预测精度, 近年来出现了两种趋势, 一种是对经典的人工神经网络进行改进和优化^[4,5], 另一种是采用组合预测的方法, 将两

种或多种预测技术融合在一起, 互用互补^[6,7]。

本文以某地区购网有功功率的负荷数据为背景, 通过仿真实验, 对 SDBP 算法、L-M 优化算法、贝叶斯正则化算法的 BP 模型 (依次称之为 SDBP、LMBP 及 BRBP 模型) 在短期负荷预测中的训练速度、预测精度和推广能力等性能进行了对比。

1 BP 神经网络

1.1 BP 神经网络结构

BP (Back Propagation) 神经网络通常是指基于误差反向传播算法 (BP 算法) 的多层前向神经网络^[8], 它是 D. E. Rumelhart 和 J. L. McClelland 及其研究小组在 1986 年研究并设计出来的。BP 神经网络通常具有一个或多个隐含层, 其中, 隐含层神经元通常采用 Sigmoid 型函数, 而输出层神经元则采用 purelin 型传递函数。图 1 给出了一个具有单隐含层的 BP 神经网络模型, 理论已经证明, 具有如图 1 所示结构的 BP 神经网络, 当隐含层神经元数目增加到足够多时, 可以以任意精度逼近任何一个具有有限间断点的非线性函数^[9]。这在结构的实现上, 要比增加更多的隐含层来提高网络训练精度要简单得多。所以绝大部分在电力负荷预测领域应用的 BP 网络都只取一层隐含层。

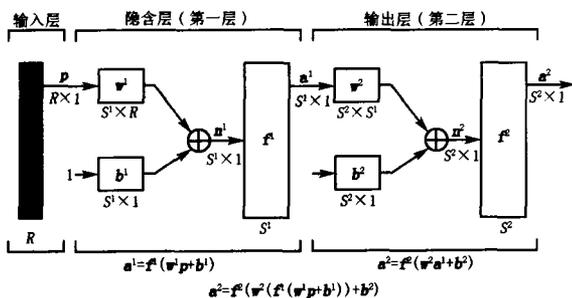


图 1 具有单隐含层的 BP 神经网络

Fig.1 BP neural network with a single connotative layer

1.2 传统的 BP 学习算法

BP 算法由两部分组成, 即信息的正向传递和误差的反向传播。在正向传递过程中, 输入信息从输入经隐含层逐层计算传向输出层, 每一层神经元的状态只影响下一层神经元的状态。如果在输出层没有得到期望的输出, 则计算输出层的误差变化值, 然后转向反向传播, 通过网络将误差信号沿原来的连接通路反向传播回来, 用以修改各层神经元的权值和偏置值, 直至达到期望目标。为了和其他改进的 BP 算法相区别, 传统的

BP 算法又称为 SDBP (Steepest Descent Backpropagation 最速下降) 算法。

1.3 L-M 学习算法

对于神经网络的学习和训练, 传统的反向传播算法迭代速度慢, 且易陷入局部最小点。针对 BP 算法的缺点, 可使用 L-M 算法 (Levenberg-Marquardt algorithm) 来改进。

网络训练的性能指数用平方误差代替均方误差, 权值调整率为:

$$\Delta W(k) = W(k+1) - W(k) = -[J^T J + \mu I]^{-1} J^T e(W)$$

其中: I 为单位矩阵, J 为误差对权值微分的矩阵, e 为误差向量, 调整参数 μ 为一标量。这个算法提供牛顿法的速度和保证收敛的最速下降法之间的一个折衷, 可以大幅度提高收敛速度, 并可以提高算法的稳定性, 减小陷入局部最小点的可能。

1.4 BR 学习算法

在人工神经网络训练过程中, 有时会出现过度拟合现象 (Overfitting)。过拟合现象是由于网络学习了太多的特殊样本, 并且过分追求拟合所有训练模式, 即要求对于所有的训练模式误差均要很小而造成的。这样, 一个“过度训练”的神经网络可能会对训练样本集达到较高的匹配效果, 但对于一个新的输入样本矢量却可能会产生与目标矢量差别较大的输出, 即神经网络不具有或具有较差的推广能力 (Generalization)。

贝叶斯正则化 BR (Bayesian Regularization 算法), 是指为了提高网络推广能力, 训练过程中要建立一个由各层输出误差、权值和阈值构成的特殊性能参数, 通过依据 L-M 优化理论对网络的权值和阈值进行调整, 使该参数最小化^[10,11]。

2 BP 神经网络的应用

2.1 模型的建立

构造人工神经网络对负荷进行预测, 主要有两种做法, 方法一是使用单一的具有 24 个输出的网络来预测每天 24 点负荷值, 方法二是构造一个规模较小的单输出网络, 针对于负荷的每一点待预测值, 分别输入一个相应的历史负荷、天气序列, 将有一个输出。

使用方法二, 由于每个网络的规模较小, 因此对网络进行训练比对一个大规模多输出的网络进行训练更加容易。而且对一天 24 点负荷构造一个网络分别进行 24 次预测, 即是考虑了不同小时类型的负荷差异, 具有较大的灵活性。故在实际中多

采用第二种方法构造神经网络对负荷进行预测。预测所用神经网络模型如图 2 所示, 为具有一个隐层的前向全神经网络。

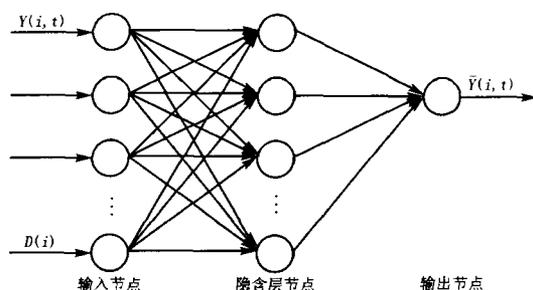


图 2 电力系统短期负荷预测模型

Fig.2 Short-term load forecasting model for power systems

以下是对应用神经网络进行负荷预测建模的几个重要问题的讨论。

1) 历史负荷数据的分析及日类型的划分

电力负荷的变化一方面有其不确定性, 如天气的变化、意外事故的发生等造成对电力负荷的随机性干扰, 另一方面, 在一定条件下, 电力负荷存在着明显的变化趋势。正是因为系统负荷具有一定的统计规律, 才可以被预测。

这里仅对日期类型进行分类, 将日类型划分为星期一、工作日(星期二至星期五)、星期六、星期日四种, 并按如表1所示对日类型进行编码后作为神经网络的输入。

表1 神经网络的日类型输入
Tab.1 Days input for neural networks

日类型	编码
星期一	00
工作日	01
星期六	10
星期天	11

2) 输入变量的选择及网络结构的确定

本文根据调度人员的运行经验和所能提供的的数据资料, 主要考虑将历史负荷数据、天气数据(主要是每日最高、最低气温及湿度)及日类型作为神经网络的输入。这样本文的训练样本组成, 即神经网络的输入输出如下:

输出为: 预测日 i 日的第 t 小时的预测负荷值

$$\bar{Y}(i, t) (t=1, 2, \dots, 24);$$

输入为: 预测日前一天 ($i-1$ 日) t 时刻前 12 点的负荷值, 和第 $i-2$ 、及 $i-3$ 、 $i-7$ 日 t 时刻周围三点的值, 以及相应的天气数据(由于数据来源限制, 只包括日最高气温 T_h 及最低气温 T_l 、最高湿度 H_h 及最低湿度 H_l) 和预测 i 日的日期类型数据 $D(i)$, 其中 $Y(i, t)$ 表示历史负荷序列。

这样, 在本文中每个神经网络的输出层神经元

个数为 1, 输入层神经元个数为 39。隐层个数的确定也很重要, 在具体设计时, 比较实际的做法是通过不同神经元数进行训练比较对比, 然后适当地加上余量。本文选取的是 12 层。

3) BP 学习速率及调整参数 μ 的选择

学习速率会影响权值与阈值更新的比例, 较大的学习速率可能造成算法不收敛, 较小的学习速率会导致训练时间增长。利用快速训练算法中提供的缺省值一般能得到比较好的效果, BP 学习速率的缺省值 $\eta=0.01$ 。同理, 调整参数 μ 的选择亦采用缺省值, 即 μ 的初始值为 0.001, μ 的增加系数为 10, 减小系数为 0.1。

4) 训练数据的前处理和后处理

由于 BP 神经网络使用的激活函数为 S 型压缩函数, 利用归一化, 将输入数据限定在 $[-1, 1]$ 区间内, 可以提高训练收敛速度, 避免计算的溢出。训练网络完成后, 采用一线性变换完成数据转换, 得到和原始输出数据单位相同的输出数据。

5) 特殊事件的处理

在负荷预测中会遇到一些特殊事件, 如检修线路、停电等, 本文根据检修及停电计划对历史负荷数据进行了恢复处理, 以减少因检修对负荷预测精度的影响。另外, 对于神经网络预测出的负荷数据, 如果预测日有检修或停电计划, 则也应根据检修或停电所影响负荷量的大小做出相应的修改, 以提高预测精度。

6) 节假日模型

用典型日样本取百分数, 用负荷变化趋势将曲线平移可得到较理想的节假日预报曲线, 节假日前后几天也属节假日范围。

2.2 BP 模型用于短期负荷预测的仿真结果

本文采用某地区购网有功功率的 24 点历史负荷数据, 对三种 BP 模型——SDBP、LMBP 及 BRBP 模型分别进行了 4 月 14 日~20 日的模拟预测。

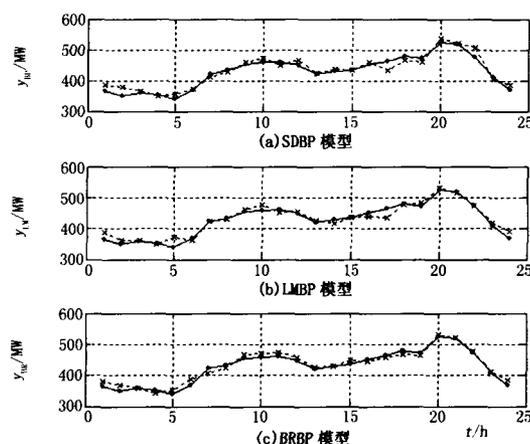


图 3 2004 年 4 月 18 日实际值与预测值曲线

Fig.3 Curves of actual values and forecasted values of 18th, April, 2004

图 3 给出了 SDBP、LMBP 及 BRBP 模型 2004 年 4 月 18 日 24 小时实际值与预测值曲线图。其中实线为实际值，虚线为预测值。

由图 3 可以明显地看出，LMBP 模型比 SDBP 模型的预测曲线对实际曲线具有更好的逼近效果，但在个别峰值处的误差变得比较尖锐。而对比后两组曲线，LMBP 模型的预测曲线毛刺较多，而 BRBP 模型的预测曲线较为光滑，显然，经贝叶斯正则化算法训练的神经网络对噪声不敏感，具有较好的推广能力，而经 L-M 算法训练后的神经网络却对样本数据点实现了“过度匹配”。

2.3 仿真分析

表 2 给出了 2004 年 4 月 14 日~20 日七天基于这三种模型的预测误差表。由表 1 可以看出，基于 LMBP 模型和 BRBP 模型的平均相对误差和每日峰值相对误差比 SDBP 模型有了很大的降低，其中 BRBP 模型的这两个误差值是最低的。

表 3 为电力负荷每点预测分别使用 SDBP 模型、LMBP 模型和 BRBP 模型进行训练所需要的平均迭代次数及迭代时间。由表 3 可知，采用 LMBP 模型进行网络训练，其平均迭代时间为 2.3 s，平均迭代次数为 3.5 次，较 SDBP 模型有了显著的改进，而 BRBP 模型收敛速度较慢，平均迭代时间为 127.0 s。

图 4 为本例网络的某次 SDBP 模型、BRBP 模型和 LMBP 模型训练误差变化曲线。对比三个训练曲线可以看到，SDBP、BRBP 模型当网络误差性能降低到或有时候甚至于未降低到目标值时就停止了训练，而 LMBP 模型由于训练速度过快，每次停止训练时，网络误差性能远远的降到了目标值以下，这

也是 LMBP 模型推广能力较差的一个原因吧。

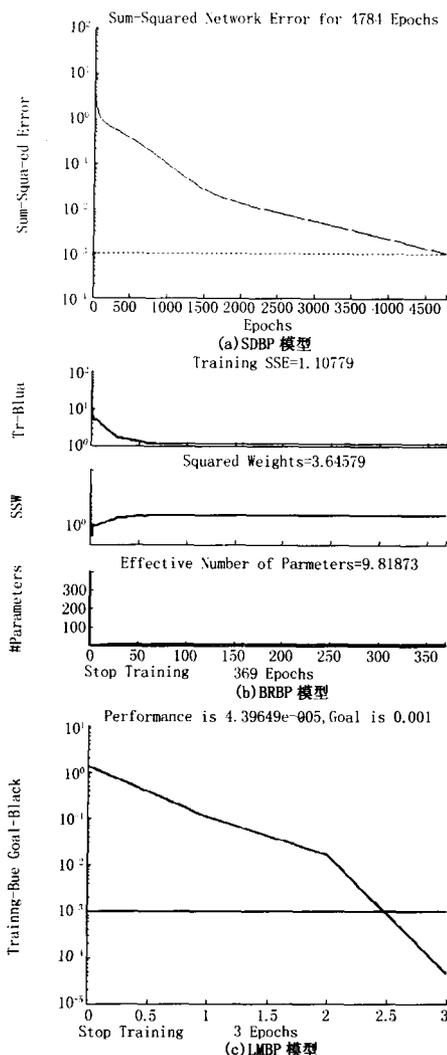


图 4 SDBP、LMBP 及 BRBP 模型训练误差变化曲线
Fig.4 Curve of training error variation of SDBP, LMBP and BRBP models

表 2 基于 SDBP 模型、LMBP 模型和 BRBP 模型的预测误差表

Tab.2 Table for forecast error of SDBP model, LMBP model and BRBP model

日期	平均相对误差 (绝对值)			最大相对误差 (绝对值)			峰值相对误差 (绝对值)		
	SDBP 模型	LMBP 模型	BRBP 模型	SDBP 模型	LMBP 模型	BRBP 模型	SDBP 模型	LMBP 模型	BRBP 模型
4.14	0.021 758	0.021 528	0.028 9	0.072 936	0.067 334	0.080 195	0.011 72	0.012 23	0.020 778
4.15	0.028 628	0.027 282	0.039 511	0.087 842	0.077 363	0.107 08	0.011 534	0.008 195 1	0.011 97
4.16	0.046 826	0.047 072	0.046 987	0.105 64	0.100 79	0.118 14	0.041 425	0.031 466	0.011 736
4.17	0.035 258	0.035 069	0.027 624	0.089 619	0.095 331	0.101 39	0.069 219	0.064 24	0.064 419
4.18	0.027 284	0.024 333	0.022 994	0.079 653	0.091 126	0.051 201	0.022 137	0.015 068	0.012 213
4.19	0.040 839	0.039 235	0.028 696	0.083 004	0.071 661	0.075 865	0.030 784	0.031 087	0.025 926
4.20	0.037 972	0.036 946	0.036 671	0.092 644	0.096 947	0.092 85	0.012 105	0.002 730 5	0.009 313
平均值	0.034 081	0.033 066	0.033 055	0.087 334	0.085 793	0.089 531	0.028 418	0.023 574	0.022 336

表 3 迭代时间及次数比较

Tab.3 Comparison of iterative time and times

SDBP 模型		LMBP 模型		BRBP 模型	
迭代次数	迭代时间/s	迭代次数	迭代时间/s	迭代次数	迭代时间/s
3637.5	73.7	3.5	2.3	256.3	127.0

3 结论

1) 由于 BP 算法本身收敛速度慢, 且易陷入局部极小, 所以, SDBP 模型的预测误差, 尤其是峰值处预测误差较大, 预测结果并不理想。

2) 当网络具有相同结构参数时, 采用 BRBP 模型可使网络的推广能力得到提高, 平均相对误差和每日峰值相对误差降低, 但收敛速度过慢 (慢于 SDBP 模型), 不适于在实际应用中采用。

3) L-M 优化算法具有较快收敛速度及稳定性, 虽然经 LMBP 模型训练后的神经网络却对样本数据点实现了“过度拟合”, 但在负荷预测中, 平均相对误差较 SDBP 模型有了很大改善, 具有良好的应用前景。

参考文献

- [1] Park D C, El-Sharkawi M A, Marks R J, et al, Electric Load Forecasting Using an Artificial Neural Network[J]. IEEE Trans on Power Systems, 1991, 6(2):442-449.
- [2] Lee K, Cha Y, Park J. Short-term Load Forecasting Using Neural Network[J]. IEEE/PWRS 1991 Winter Meeting, 1991.
- [3] Peng T M, Hubele N, Karady G. Advancement in the Application of Neural Network for Short-term Load Forecasting[J]. IEEE/PWRS 1991 Summer Meeting, 1991.
- [4] Carpinteiro O A S, Reis A J R, da Silva A P A. A Hierarchical Neural Model in Short-term Load Forecasting[J]. Applied Soft Computing, 2004:405-412.

- [5] Kodogiannis V S, Anagnostakis E M. A Study of Advanced Learning Algorithms for Short-term Load Forecasting[J]. Engineering Applications of Artificial Intelligence, 1999:159-173.
- [6] Srinivasan D, et al. Parallel Neural Network-fuzzy Expert System Strategy for Short-term Load Forecasting System Implementation and Performance Evaluation[J]. IEEE Trans on Power Systems, 1999, 14(3): 1100-1106.
- [7] Kim Chang-il, Yu In-keun, Song Y H. Kohonen Neural Network and Wavelet Transform Based Approach to Short-term Load Forecasting[J]. Electric Power Systems Research, 2002, 63:169-176.
- [8] Hagan M T, Demuth, H B, Beale M H. Neural Network Design[M]. DAI Kui, et al trans. Beijing: China Machine Press, 2002.
- [9] Hornik K M, Stinchcombe M, White H. Multilayer Feedforward Networks are Universal Approximators[J]. Neural Networks, 1989, 2(5):359-366.
- [10] Hinton G E. Connectionist Learning Procedures[J]. Artificial Intelligence, 1989, 40:185-234.
- [11] Weigand A S, Rumelhart D E, Huberman B A. Generalization by Weight Elimination with Application to Forecasting[A]. In: Advances in Neural Information Processing Systems[C]. San Mateo(CA): Morgan Kaufmann. 1991. 575-582.
- [12] 许东, 吴铮. 基于 MATLAB6.X 的系统分析与设计——神经网络 (第二版) [M]. 西安: 西安电子科技大学出版社, 2002.

收稿日期: 2006-09-17; 修回日期: 2006-12-13

作者简介:

李晓波 (1973-), 女, 本科, 实验师, 主要从事自动化技术方面的实验教学及研究工作; E-mail: lixbh@163.com

罗枚 (1968-), 女, 硕士, 讲师, 主研领域为控制理论及控制应用。

(上接第 48 页 continued from page 48)

- [9] 张大海, 毕研秋, 等. 基于串联灰色神经网络的电力负荷预测方法[J]. 系统工程理论与实践, 2004, (12): 128-132.
ZHANG Da-hai BI Yan-qiu, et al Power Load Forecasting Method Based on Serial Grey Neural Network[J]. System Engineering Theory and Practice, 2004, (12):128-132.
- [10] 文艳, 宋宗勋, 张国柱, 等. 基于灰色关联-神经网络模型的城市电力负荷短期预测的研究与应用[J]. 继电器, 2005 33(19): 36-40.

WEN Yan, SONG Zong-xun, ZHANG Guo-zhu, et al. Research and Application of Grey-connection Neural-network Model in City Short-term Electric Power Load Forecast[J]. Relay, 2005 33(19): 36-40.

收稿日期: 2006-10-18

作者简介:

吴耀华 (1970-), 男, 讲师, 主要从事电力系统规划方面的研究。E-mail: wyh966@snut.edu.cn