

基于气象累积和 ACA-GRNN 的短期电力负荷预测

李如琦, 杨立成, 莫仕勋, 苏媛媛, 唐卓贞

(广西大学电气工程学院, 广西 南宁 530004)

摘要: 针对气象条件具有累积效应以及不同气象条件对负荷影响的程度不同的特点, 采用一加权的几何距离公式来选取神经网络的训练样本, 不仅加快了神经网络的训练速度, 而且加强了神经网络的逼近能力。同传统的神经网络相比, 广义回归神经网络的训练过程实际上是不断地调整平滑参数 σ 的过程, 因此, σ 的不同取值对网络的输出具有重要的影响。在优化广义回归神经网络的平滑参数 σ 时, 采用基于蚁群种群的新型优化算法——蚁群算法来优化, 在很大程度上减少了人为选择参数的主观影响。最后通过实例验证了该模型的有效性。

关键词: 负荷预测; 气象累积; 广义回归神经网络; 优化; 蚁群算法

Short-term electric load forecasting based on accumulated weather and ACA-GRNN

LI Ru-qi, YANG Li-cheng, MO Shi-xun, SU Yuan-yuan, TANG Zhuo-zhen

(School of Electrical Engineering, Guangxi University, Nanning 530004, China)

Abstract: According to the features of accumulated effects of weather condition and different effects for load with different weather condition, a geometric distance formula with different weights is adopted in this paper, which can speed the training and strengthen the approximation of neural network. The training process of general regression neural network (GRNN) is in fact to adjust the smooth parameter σ compared with the traditional neural network, so that different values of σ have major impact on outputs of network. In the course of optimizing smooth parameter σ of GRNN, a new type optimization algorithm—Ant Colony Algorithm (ACA) based on population of ant colony is employed, which can reduce the subjective effects to a large extent in the course of selecting the parameters. Finally, an example is given to show the effectiveness of the model.

Key words: load forecasting; accumulated weather; general regression neural network; optimization; ant colony algorithm

中图分类号: TM715 文献标识码: A 文章编号: 1003-4897(2008)04-0058-05

0 引言

准确的短期电力负荷预测可以经济合理地安排机组的启停, 保证电网运行的安全与稳定, 提高电力企业的经济效益和社会效益^[1]。

近些年来, 随着其它学科理论的不断发展和完善, 负荷预测技术也经历了从基于数理统计的传统预测方法到基于人工智能的现代预测方法的发展, 特别是九十年代以来, 人工神经网络技术得到了空前的发展, 其在负荷预测中的应用研究也成为了热点之一^[2-4]。

目前, 神经网络中的 BP 网络在短期负荷预测中得到了广泛的研究, 取得了一定的成果, 但是因其隐层神经元个数、隐层数难以确定, 往往影响了预测效果。尽管许多学者对此作了许多改进, 但仍未形成统一的结论。本文所采用的广义回归神经网络

(GRNN) 是建立在数理统计基础上的一种新型神经网络, 具有计算速度快、网络结构可以自动确定等优点, 一旦样本确定, 网络的训练实际上只是确定隐回归单元核函数中的平滑参数 σ 的过程。通过建立目标函数, 最终将问题转化为关于 σ 的函数优化问题。针对传统的优化算法受到许多条件的制约且易于陷入局部最优解的缺点, 本文采用一种新型的模拟仿生算法——蚁群算法对其进行优化求解, 可以有效地避免局部极优。同时, 在神经网络进行训练时充分考虑气象条件的累积效应, 即某日的气象条件可能影响连续几日的负荷预测, 采用加权的几何距离公式选取与预测日气象条件最相近的数日作为神经网络的训练样本, 既体现了不同的气象条件对负荷预测影响程度的不同, 又提高了神经网络的泛化能力。

1 气象因素分析

1.1 气象条件的累积

影响负荷预测精度的因素很多,其中气象条件是主要影响因素之一。如本文所研究的对象是广西某地区的主网负荷,该地区负荷基值比较小,发自自供的小水电众多,工业负荷所占的比例也不如大电网的高,气象条件的变化往往会造成主网负荷较大的波动,并且气象条件(如某日较大的降雨)不仅会影响到该日的负荷,还可能影响连续几日的负荷。针对气象条件的这种累积效应,文献[5]采用了“累积因子”来处理气象信息:

定义 第*i*日第*j*个气象特征相对值 $L'_{i,j}$ 与实际值 $L_{i,j}$ 的关系为

$$L'_{i,j} = L_{i,j} + r_{i,j} \cdot L'_{i-1,j} \quad (1)$$

式中: $i, j = 1, 2, 3, \dots$, $r_{i,j}$ 为各气象特征量的“累积因子”。

在计算时,采用上述折算方案充分体现了气象特征值的“累积效应”,但并不是所有范围内的气象值都有明显的累积效应,有的气象值只有达到一定的阈值时才表现出一定的累积效应,现以本文所研究的广西某地区2005年和2006年的气象与负荷资料进行举例说明。对历史资料进行研究发现,该地区的负荷受降雨、最高温度、最低温度的影响较大,因此这里以降雨累积、高温累积、低温累积作为主要的研究对象。统计分析表明,在该地区,只有当某日的降雨量达到了中雨量级以上(大于25 mm)、在夏季连续数天的高温(大于32℃)、在冬季连续数天的低温(小于10℃)时才表现出一定的累积效应。为此,本文引入“累积阈值函数” μ_j 对公式(1)做如下修正:

假设第*i*日的第*j*个气象因素值对其后面的第*k*日的气象累积分量 $w'_{i,k}$ 为

$$w'_{i,k} = h_k \cdot w_{i,j} \cdot \mu_j \quad (2)$$

其中: $k=1, 2, \dots, L$,这里的*L*不宜过大,因为时间间隔越长,这种累积效应就越不明显; h_k 为时间权重因子且应遵循“近大远小”原则,即 $h_1 > h_2 > \dots > h_L$; $w_{i,j}$ 为第*i*日的第*j*个气象因素的实际值; μ_j 为第*j*个气象因素的“累积阈值函数”,在本文中,令 μ_1 、 μ_2 、 μ_3 分别为降雨、最高温度、最低温度的“累积阈值函数”,其值如下:当第*i*日的降雨超过25 mm时 $u_1=1$,否则 $u_1=0$;

当第*i*日之前连续3天的最高温度超过32℃时 $u_2=1$,否则 $u_2=0$;当第*i*日之前连续3天的最低温度小于10℃时 $u_3=1$,否则 $u_3=0$ 。

定义公式(2)以后即可确定第*n*日的第*j*个气象值经折算后的值 $w''_{n,j}$:

$$w''_{n,j} = w_{n,j} + \sum_{m=1}^H w'_{m,n} \quad (3)$$

式中: $w_{n,j}$ 为第*n*日第*j*个气象因素的实际值; $w'_{m,n}$ 为前*H*日的第*j*个气象值分别在第*n*日的累积分量,这里应有 $H \leq L$ 。

1.2 气象条件“相似”的评价函数

由于我国各地区产业结构、经济状况、地理位置等客观因素的影响,不同气象条件对各电力系统负荷的影响程度不同。按照上述气象累积效应,本预测模型根据待预测日与已知日气象状况的“相近”程度来选取训练样本,即采用下述加权几何距离公式作为选取神经网络训练样本的评价函数:

$$\min(d_s) = \sum_{i=1}^n (w_i [T_i(S) - R_i]^2) \quad (4)$$

其中:*S*为预测日之前的某一日; w_i 为第*i*个气象因素对负荷影响的重要程度系数; $T_i(S)$ 为*S*日的第*i*个气象因素; R_i 为预测日的第*i*个气象因素。

2 广义回归神经网络

广义回归神经网络(General Regression Neural Network)是由 Donald F. Specht 在1991年提出的一种建立在数理统计基础上的新型神经网络^[6]。它的网络结构简单,即使样本数据较少,也可以收敛于最优回归平面,并且只要样本数据确定,即可自动确定其网络结构,而不必像传统的神经网络那样需要人为地确定隐层数及隐层神经元个数,从而可以尽量地减少人的主观经验对预测结果的影响。

设随机变量*x*和*y*的联合概率密度函数为 $f(x, y)$,当 $x=x_0$ 时,*y*对 x_0 的条件均值为:

$$E(y|x_0) = \hat{y}(x_0) = \frac{\int_{-\infty}^{\infty} y f(x_0, y) dy}{\int_{-\infty}^{\infty} f(x_0, y) dy} \quad (5)$$

利用*n*组样本观测值 $(x_i, y_i), i=1, 2, \dots, n$,对 $f(x_0, y)$ 进行非参数估计:

$$\hat{f}(x_0, y) = \frac{1}{(2\pi)^{(p+1)/2} \sigma^{p+1}} \cdot \frac{1}{n} \sum_{i=1}^n \exp\left(-\sum_{j=1}^p (x_{0j} - x_{ij})^2 / 2\sigma^2\right) \exp\left(-\frac{1}{2\sigma^2} (y - y_i)^2\right) \quad (6)$$

式中: n 为样本容量, p 为 x 的维数, σ 为高斯函数的宽度系数, 在此称为平滑参数。由于积分

$\int_{-\infty}^{\infty} x e^{-x^2} dx = 0$, 将式(6)代入式(5)并整理有:

$$\hat{y}(x_0) = \frac{\sum_{i=1}^n y_i \exp\left(-\sum_{j=1}^p (x_{0j} - x_{ij})^2 / 2\sigma^2\right)}{\sum_{i=1}^n \exp\left(-\sum_{j=1}^p (x_{0j} - x_{ij})^2 / 2\sigma^2\right)} \quad (7)$$

根据式(7)可构造广义回归神经网络结构, 如图1所示, 它由输入层、模式层、求和层和输出层构成, 同RBF网络的结构类似, 其模式层(隐回归层)一般采用高斯核函数 $\exp(-\|x^{(p)} - c_j^{(p)}\|^2 / 2\sigma_j^2)$ 作为某个神经元 j 的传递函数, $x^{(p)}$, $c_j^{(p)}$ 分别为神经网络的 p 维输入向量和模式层神经元 j 所对应的核函数的 p 维中心矢量。求和层共有分子、分母两个单元, 分别对应着式(7)的分子和分母。输出层单元首先将求和层的分子、分母单元相除, 然后再将结果进行输出^[7,8]。

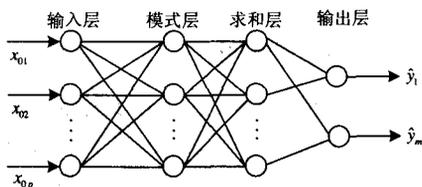


图1 GRNN 的结构

Fig.1 The structure of GRNN

3 蚁群优化算法

3.1 目标函数的建立

由于GRNN的学习算法在训练过程中不用调整神经元之间的连接权值, 而是通过改变平滑参数 σ 来调整模式层中各单元的传递函数进而不断地改变输出结果, 因而确定最佳的平滑参数 σ 对GRNN的预测结果具有重大影响。从理论上讲, σ 越小, 对函数的逼近就越精确, 因此本文令 σ 属于 $(0, 10]$ 区间即可满足要求。按照公式(2)、(3)、(4)选取训练样本, 并分成两部分, 一部分用于神经网络的训练, 一部分用于测试。定义目标函数如下:

$$\min f(\sigma) = \frac{1}{N} \sum_{j=1}^N \sum_{i=1}^L [\hat{y}_{ij}(\sigma) - y_{ij}]^2 \quad (8)$$

其中: N 为测试的样本数, 即预测的天数; L 为每天预测的点数; $\hat{y}_{ij}(\sigma)$ 为第 j 天的第 i 点采用某个平滑参数值 σ 的预测值; y_{ij} 为第 j 天的第 i 个点的实际值。

定义上述目标函数后, 问题转化为在 $(0, 10)$ 区间内求式(8)的函数优化问题。针对传统的优化方法受到许多条件的限制且易陷入局部极优的缺点, 本文尝试采用一种新型的全局搜索算法——蚁群算法来进行优化, 从而有效地解决了这个问题。

3.2 基本的蚁群优化算法

蚁群算法(Ant Colony Algorithms)是由意大利学者M.Dorigo于1991年首先提出的一种基于蚂蚁种群的新型优化算法, 具有较强的鲁棒性、分布式计算、易于与其它算法相结合等优点。它最初用于解决旅行商问题(TSP), 目前, 蚁群算法在许多领域已经获得了成功的应用。基本的蚁群算法详见参考文献[9], 只要对此模型作适当的修改便可以用来求解其它的问题。

3.3 改进的蚁群算法

由于最初的蚁群算法起源于优化离散型的网络路径问题, 因此, 在将蚁群算法用于一般函数的优化问题时, 必须对算法中许多实施的细节加以修正^[10-12]。假设目标函数为:

$$\min f(\sigma) \quad \sigma \in [a, b] \quad (9)$$

首先, 将问题的解空间分解成若干个小区域, 在每个小区域中确定某个点作为蚂蚁的初始位置, 各个区域内的蚂蚁按如下概率进行转移:

$$p_{ij} = \begin{cases} \frac{\tau_j^\alpha \eta_{ij}^\beta}{\sum_k \tau_k^\alpha \eta_{ik}^\beta} & \eta_{ij} > 0 \\ 0 & \eta_{ij} \leq 0 \end{cases} \quad (10)$$

其中: τ_j 为解空间中第 j 个小区域的邻域吸引强度, 期望值 $\eta_{ij} = f_i^* - f_j^*$, 即第 i 个小区域与第 j 个小区域当前最优解所对应的优化函数值的差值, α, β 两参数分别表示蚂蚁在进行状态转移时各区域的邻域吸引强度和期望值的重要程度。然后处在不同区域内的蚂蚁按照转移概率或者进行移动, 或者进行区域内的邻近搜索。通过不断地重复上述过程, 最终一定可以寻找到问题的全局最优解或较好

解。

应用上述改进的蚁群算法优化平滑参数 σ 的具体步骤如下:

Step1: 首先确定要优化的平滑参数 σ 的取值范围, 本文令 $\sigma \in (0, 10]$, 然后将解空间按照某种规则划分成 N 个区域。

Step2: 初始化蚁群算法的各个参数、最优解 σ^* 及最优函数值 $f(\sigma^*)$ 。并将 m 只蚂蚁以一定的分布方式置于 N 个区域。

Step3: 所有蚂蚁都按照转移概率 p_{ij} 进行区域间的移动, 并引进邻域局部搜索机制, 记录当前的最优解 σ^* 及最优函数值 $f(\sigma^*)$ 。

Step4: 按 $\tau_j(t+1) = \rho \cdot \tau_j(t) + \sum_k Q/L_j$ 更新第 j 个区域的邻域吸引强度, 这里 L_j 表示在本次循环中 $f(\sigma)$ 的变化量, $1-\rho$ 为信息素的挥发系数, Q 为常数。

Step5: 若小于预先设定的最大迭代次数, 则重新设置蚂蚁在各区域内的位置并转到 Step3, 否则输出当前的最优解 σ^* 及最优函数值 $f(\sigma^*)$ 。

4 算例

采用上述预测模型, 应用广西某地区电网 2005 年 9 月 2 日之前的实际主网负荷和气象数据预测该日的整点负荷。首先将负荷数据进行预处理, 归一化(以防止神经元出现饱和现象), 然后按照公式(2)、(3)、(4)选取训练样本, 并利用改进的蚁群优化算法根据所选样本确定平滑参数 σ , 初始参数设置为 $\alpha=1$, $\beta=5$, $Q=100$, $\rho=0.9$ 。最后以预测日的气象条件及前一日的整点负荷作为神经网络的输入, 预测的整点负荷作为输出, 并进行误差修正, 可得预测结果如表 1 中的相对误差 1 所示。为了便于比较分析, 同时采用不考虑气象累积的 ACA-GRNN 预测模型、单独的 GRNN 模型进行预测, 所得结果分别为表 1 中的相对误差 2 和相对误差 3。

根据表 1 可知, 本模型预测的最大相对误差为 4.2848%, 平均相对误差为 1.7463%, 而不考虑气象累积的 ACA-GRNN 模型预测的最大相对误差为 5.4593%, 平均相对误差为 2.7260%, 单独的 GRNN 模型预测的最大相对误差为 6.8874%, 平均相对误差为 3.1721%。由此可见, 采用基于气象累积的 ACA-GRNN 模型后预测精度有了一定的提高, 对该日的预测取得了比较满意的效果。

表 1 2005 年 9 月 2 日各时刻预测的相对误差

Tab.1 Relative errors of all moments of Sep.2,2005

时间/h	相对误差		
	1/(%)	2/(%)	3/(%)
1:00	1.1137	2.4939	3.9106
2:00	0.8946	1.7582	2.9123
3:00	-0.7273	0.2522	1.1284
4:00	4.2848	5.4593	6.8874
5:00	2.9833	3.7570	4.5276
6:00	0.5112	-0.5659	-0.5153
7:00	-1.4449	-0.1799	0.1690
8:00	-3.2972	-2.1013	-2.8335
9:00	-0.8638	1.2028	1.2611
10:00	-1.4645	1.9445	2.3917
11:00	0.1944	3.4321	3.9876
12:00	-1.9981	1.4905	2.1386
13:00	-0.8848	2.8534	3.2238
14:00	0.6776	4.9652	5.5967
15:00	1.0823	4.7749	5.2913
16:00	-2.3610	1.4317	1.6545
17:00	-0.4333	1.9943	2.0244
18:00	0.8523	3.4288	3.2867
19:00	-2.1567	-0.0344	-0.2601
20:00	3.1342	3.8666	3.8242
21:00	3.7662	5.1870	5.1484
22:00	2.5318	5.2674	5.7372
23:00	2.0343	4.7836	5.2228
24:00	-2.2198	2.1982	2.1982

5 结束语

本文采用了计算速度快、网络结构可以自动确定的 GRNN 网络建立了负荷预报模型。同时, 在神经网络训练时充分考虑了气象条件的累积效应, 根据加权的几何距离公式来选取训练样本, 并利用具有全局寻优能力的新型优化算法——蚁群算法来优化 GRNN 的平滑参数, 具有一定的理论意义和现实意义。

需要指出的是, 蚁群算法是一种新型的优化算法, 它在解决组合优化问题时表现出了良好的性能, 在求解连续函数优化方面也有了一些研究, 但在计算速度、收敛性等方面仍然存在着一定的缺陷, 需要不断的改进和完善。本文对蚁群算法在参数优化中的应用进行了初步的探讨, 如何利用计算速度更快、收敛性更好的改进蚁群算法来解决参数优化问题, 将是本文今后主要的研究方向。

参考文献

- [1] 牛东晓, 曹树华, 赵磊, 等. 电力负荷预测技术及其应用[M]. 北京: 中国电力出版社, 1998.

- NIU Dong-xiao, CAO Shu-hua, ZHAO Lei, et al. The Technology of Power Load Forecasting and Its Application[M]. Beijing: China Electric Power Press, 1998.
- [2] HUANG Guang-bin, ZHU Qin-yu, Chee-Kheong Siew. Real-Time Learning Capability of Neural Networks[J]. IEEE Trans on Neural Networks, 2006, 17(4): 863-878.
- [3] 谢宏, 陈志业, 牛东晓, 等. 基于小波分解与气象因素影响的电力系统日负荷预测模型研究[J]. 中国电机工程学报, 2001, 21(5): 5-10.
XIE Hong, CHEN Zhi-ye, NIU Dong-xiao, et al. The Research of Daily Load Forecasting Model Based on Wavelet Decomposing and Climatic Influence[J]. Proceedings of the CSEE, 2001, 21(5): 5-10.
- [4] Hippert H S, Pedreira C E, Souza R C. Neural Networks for Shortterm Load Forecasting: a Review and Evaluation[J]. IEEE Trans on Power Systems, 2001, 16(1): 44-55.
- [5] 胡子珩, 陈晓平, 刘顺桂, 等. 深圳电网自动运行的短期负荷预测系统[J]. 电网技术, 2003, 27(5): 21-25.
HU Zi-heng, CHEN Xiao-ping, LIU Shun-gui, et al. An Autooperating Short-Term Load Forecasting System for Shenzhen Power Network[J]. Power System Technology, 2003, 27(5): 21-25.
- [6] Specht D F. A General Rergrression Neural Network[J]. IEEE Trans on Neural Networks, 1991, 2(6): 568-576.
- [7] 吴耀华. 基于GM-GRNN的电力系统长期负荷预测[J]. 继电器, 2007, 35(6): 45-48.
WU Yao-hua. Long Term Load Forecasting Based on GM-GRNN in Power System[J]. Relay, 2007, 35(6): 45-48.
- [8] 谷志红, 牛东晓, 王会青. 广义回归神经网络模型在短期电力负荷预测中的应用研究[J]. 中国电力, 2006, 39(4): 11-14.
GU Zhi-hong, NIU Dong-xiao, WANG Hui-qing, Research on Application of General Regression Neural Network in Short-term Load Forecasting[J]. Electric Power, 2006, 39(4): 11-14.
- [9] 李士勇, 等. 蚁群算法及其应用[M]. 哈尔滨: 哈尔滨工业大学出版社, 2004.
LI Shi-yong, et al. Ant Colony Algorithms with Applications[M]. Harbin: Harbin Institute of Technology Press, 2004.
- [10] 詹士昌, 徐婕. 用于多维函数优化的蚁群算法[J]. 应用基础与工程科学学报, 2003, 11(3): 223-229.
ZHAN Shi-chang, XU Jie. An Ant Colony Algorithm Which Applying to the Multidimensional Function Optimization Problems[J]. Journal of Basic Science and Engineering, 2003, 11(3): 223-229.
- [11] 马良. 基于蚂蚁算法的函数优化[J]. 控制与决策, 2002, 17(增刊): 719-722.
MA Liang. Ant Algorithm Based Function Optimization[J]. Control and Decision, 2002, 17(S): 719-722.
- [12] 赵宝江, 金俊, 李士勇. 一种求解函数优化的自适应蚁群算法[J]. 计算机工程与应用, 2007, 43(4): 40-43.
ZHAO Bao-jiang, JIN Jun, LI Shi-yong. Adaptive Ant Colony Algorithm for Function Optimization[J]. Computer Engineering and Applications, 2007, 43(4): 40-43.

收稿日期: 2007-08-16; 修回日期: 2007-10-22

作者简介:

李如琦(1959-), 女, 副教授, 主要研究方向为电力系统最优运行与规划、人工智能; E-mail: liruqi59@gxu.edu.cn

杨立成(1981-), 男, 硕士研究生, 主要研究方向为电力系统最优运行与规划、人工智能;

莫任勋(1970-), 男, 工程师, 主要研究方向为电力系统自动化控制。

(上接第 57 页 continued from page 57)

- [9] 鞠平, 谢欢, 孟远景, 等. 基于广域测量信息在线辨识低频振荡[J]. 中国电机工程学报, 2005, 25(22): 56-60.
JU Ping, XIE Huan, MENG Yuan-jing, et al. Online Identification of Low-Frequency Oscillations Based on Wide-Area Measurements[J]. Proceedings of the CSEE, 2005, 25(22): 56-60.
- [10] 谢小荣, 肖晋宇, 童陆园, 等. 采用广域测量信号的互联电网区间阻尼控制[J]. 电力系统自动化, 2004, 28(2): 37-40.
XIE Xiao-rong, XIAO Jin-yu, TONG Lu-yuan, et al. Inter-are Damping Control of Interconnected Power Systems Using Wide-area Measurements[J]. Automation

of Electric Power Systems, 2004, 28(2): 37-40.

收稿日期: 2007-06-11; 修回日期: 2007-08-22

作者简介:

王茂海(1976-), 男, 博士, 工程师, 主要从事广域测量系统的高级应用、EMS 高级应用等方面的工作; E-mail: wang.maohai@ncgc.com.cn

谢开(1971-), 男, 博士, 从事电网调度管理、自动化管理、电力市场等方面工作;

徐正山(1963-), 男, 硕士, 高级工程师, 从事电网调度自动化方面的工作。