

短期负荷预测相关因素的自适应训练

高峰, 康重庆, 程旭, 沈瑜, 夏清, 彭涛, 周安石

(清华大学电机系, 北京市 100084)

摘要: 提高预测精度是短期负荷预测的基本目标。目前已提出了处理相关因素的规范策略和短期负荷预测的综合模型。在此基础上, 将自适应训练的思想引入到短期负荷预测相关因素处理中, 提出了相关因素自适应训练的若干概念, 并分析了自适应训练中的基本问题, 给出了短期负荷预测过程的抽象化模型, 提出了两种训练负荷相关因素的算法: 摄动算法和遗传算法, 最后比较了这两种算法的优缺点。算例分析表明, 通过自适应训练相关因素, 实际预测的效果得到显著改善。

关键词: 短期负荷预测; 虚拟预测; 相关因素; 综合模型; 摄动算法; 遗传算法

中图分类号: TM715; TP18

0 引言

短期负荷预测是电力系统的重要研究课题。影响电力系统负荷曲线变化的因素很多, 如日类型、天气状况和一些不确定性因素等。文献[1]中提出了规范化的处理规律性变化的相关因素的短期负荷预测策略, 核心思想是建立影响预测效果的相关因素映射数据库。此外, 针对短期负荷预测问题, 人们已经提出了多种模型, 根据各种单一模型构造综合模型是提高预测精度的有效途径, 文献[2]从虚拟预测的角度提出了短期负荷预测的综合模型。显然, 基于以上思路, 映射库的设计和取值是一个核心问题。按照原来的设计思想^[1,2], 各种相关因素的映射表长度是由用户根据经验定义的, 各个映射对(相关因素取值——映射后的取值)也是用户自己摸索的经验结果。用户根据经验, 先设计多种映射方案, 然后进行虚拟预测, 从中挑选效果比较满意的一种方案作为自己地区的映射表。但是, 这样做工作量很大, 而且列举的映射方案总是有限的, 容易丢弃许多较优的方案。因此, 对映射表的自适应^[3]训练很有必要。

自适应训练的思想在人工神经网络中得到了集中体现, 这种思想意味着网络训练是一种独立的、无外部控制的操作^[3,4]。一个自适应系统可以从自身的挫折、对外部世界的观察和经历中获得学习。当条件发生变化时, 系统能够对自身进行调整。人工神经网络的训练算法是自适应训练算法的代表, 本文把自适应训练思想引入到短期负荷预测的一般性预测方法中。这里“自适应”的含义是: 针对任何一个地区的

历史资料, 不论用户设定的原始映射表如何, 此训练过程总是可以找到一个比较合理的新映射表, 在效果上明显优于原始映射表, 从而优化预测结果。

本文描述了自适应训练的一些基本概念, 提出了训练相关因素映射数据库的摄动算法^[5], 该方法思路清晰, 易于编程实现, 为进一步改善计算结果, 提出了利用遗传算法^[6]训练相关因素映射数值的新思路, 实践证明, 预测的精度进一步得到提高。

1 概念分析

如图 1 所示, 整个时间轴上有历史起始日、历史基准日和预测终止日 3 个分界点, 得到 2 个时间区间 A 和 B。这里举例说明: 假设预测 2002 年 1 月 12 日至 1 月 18 日连续一星期的负荷, 那么根据图 1, 历史起始日是 2001-12-14; 历史基准日是 2002-01-11; 预测终止日是 2002-01-18; 区间 A 包括 2001-12-14 至 2002-01-11; 区间 B 包括 2002-01-12 至 2002-01-18。



图 1 预测中时间序列图

Fig. 1 Diagram of time sequence in forecasting

图 2 具体描述了本例中预测的时间序列关系。

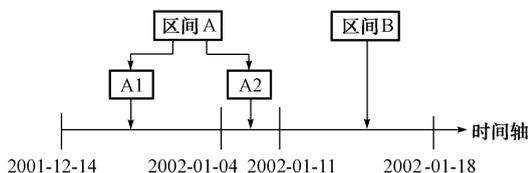


图 2 时间序列图的一个例子

Fig. 2 An example for diagram of time sequence

下面参照图 1 和图 2 解释几个基本概念。

1.1 参数辨识

首先,认为区间 A 上的条件均已知,通过自变量(例如气象因素、时间等,用 X 表示)与因变量(电力负荷,用 L 表示)的分析,得到待定量(预测模型的参数,用 S 表示)。则可抽象地表示为:

$$L_t = f(X_t, S)$$

以 S 为待定参数, X, L 作为已知量,进行参数辨识,可得到参数辨识结果。后续的预测过程为:

$$\hat{L}_t = f(X_t, \hat{S})$$

1.2 虚拟预测

将图 1 中区间 A 分为 A1 和 A2 两个部分。从图 2 中可看出: A1 包括 2001-12-14 至 2002-01-04; A2 包括 2002-01-05 至 2002-01-11。其中, A1 占 A 的绝大部分,认为仍然是已知量; A2 占 A 的很小部分,暂时看成是未知量(待预测)。以 A1 中所有已知条件进行参数辨识后,对 A2 中的所有时段做出假想的预测。由于 A2 中实际数据本来已知,因此可用于分析辨识与这个假定预测的效果的差异,故对 A2 中各时段的预测称为虚拟预测。

一般来说, A1 为 A 的前面部分, A2 为 A 的后面部分,即以最近期的若干时段做虚拟预测。但这不是绝对的。例如,今天是星期四,已知星期三以前的所有数据,很可能选定的虚拟预测日期为本星期三、二和上星期四。此时, A1 和 A2 在时间轴上有交错。

1.3 反馈调整

虚拟预测给出了以 A1 中参数辨识结果预测 A2 中已知数据的效果,如果将这个预测结果与实际数据的差异进行分析,将分析结果作为调整方向引用到 A1 中的参数辨识中去,则形成一个反馈调整过程。显然,这个反馈使预测过程成为闭环。

由于一般情况下 A2 应取最近的若干时段,这时,反馈调整就是以最新时段的信息对原来的参数辨识做出调整。因此,是一种“新息预测”(这是灰色系统^[7]的思路),它及时反映了电力负荷近期的最新变化,克服了静态预测的不足。

1.4 滚动训练

滚动训练是灰色系统中等维递补的思想^[7],如图 3 所示。

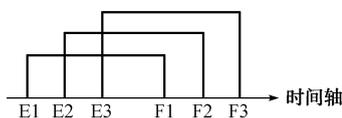


图 3 滚动训练示意图

Fig. 3 Diagram of rolling training

首先设定一个数据窗的宽度,认为这个数据窗内的数据对后期的预测是有效的,这个窗以前的数据已不起作用。这样,随着“新息”的不断加入,数据窗不断移向时间轴的右侧。每次训练总是以当前窗中的有效数据为依据,从而实现滚动训练。

2 问题描述

2.1 短期负荷预测的抽象化分析

各种短期负荷预测的单一方法和综合模型建立在规范化处理相关因素策略^[1]的基础上,方法的共性可以抽象描述如下。

为方便起见,定义如下几个变量:

- a. 相关因素数目为 m 。
- b. 数据采样天数为 $n+N$ 天,其中第 1~第 n 天数据均已知。第 $n+1$ ~第 $n+N$ 天仅已知相关因素,负荷待预测。
- c. k 为相关因素下标, i 为日期下标, t 为时段下标。
- d. 第 $k(k=1, 2, \dots, m)$ 个相关因素的映射表描述如下:

$$a_k = [a_{k1}, a_{k2}, \dots, a_{kj}, \dots, a_{kl_k}]$$

⇕

$$b_k = [b_{k1}, b_{k2}, \dots, b_{kj}, \dots, b_{kl_k}]$$

这里 l_k 为第 k 种相关因素映射表的分段点数。

- e. x_{ik}, y_{ik} 分别表示第 i 天第 k 种相关因素映射前和映射后的取值。
- f. l_{it}, \hat{l}_{it} 分别表示第 i 天第 t 点负荷的实际值和预测值。

g. 映射过程如下:对于分段点(如 a_{kj}),直接得到映射值(b_{kj});对于非分段点,采取线性插值。

为了方便叙述,以下将第 1~第 n 天以集合下标 1 表示,第 $n+1$ ~第 $n+N$ 天以集合下标 2 表示。则有: $X = [X_1, X_2]$ 为相关因素原始值矩阵,其元素为 x_{ik} ; $Y = [Y_1, Y_2]$ 为相关因素映射值矩阵,其元素为 y_{ik} ; $A = [a_1, a_2, \dots, a_k, \dots, a_m]$, 为映射表自变量; $B = [b_1, b_2, \dots, b_k, \dots, b_m]$, 为映射表因变量; 令 $Y = g(X, A, B)$ 为映射过程的抽象函数,且 $Y_1 = g(X_1, A, B)$, $Y_2 = g(X_2, A, B)$; $L_1 = h(Y_1, S)$ 为拟合过程的抽象函数; $L_2 = h(Y_2, \hat{S})$ 为虚拟预测过程的抽象函数; S 为模型的内在参数。可得 $L = f(X, A, B, S)$ 为完整的抽象描述模型,其含义是:当给定了映射库参数 A, B 后,对于已知相关因素 X 的取值后,其预测值便可以确定。而改变一组 (A, B) 取值,在 X 不变的情况下, \hat{L} 就有可能发生变化。那么,当 (A, B) 不断变化时,预测值 \hat{L} 就有可能得到优化。

因此,映射库训练的基本原理是:在当前的映射

表基础上,对映射库的元素做出尝试性的调整,如果调整是有效的(促使虚拟预测的结果好转),则接受这个调整;否则,拒绝这个调整。如此循环,直至没有更好的调整出现为止。

通过上述分析可得出对相关因素映射库的映射函数进行训练的思路:认为映射库中 A 是不用改变的,只需改变映射后取值 B 。这是有实际意义的,即认为某因素映射的分段数、分段点取值均已确定,只需优化调整其对应的映射后取值 B ,达到优化效果。

2.2 基于虚拟预测思想的综合模型策略

文献[2]提出的短期负荷预测综合模型的思路是:利用单一方法对历史日负荷进行假定的预测(即虚拟预测),根据预测的结果做出各个单一方法的权重的判断,形成综合模型预测结果。根据这种思路,综合模型是下面的一个非线性规划问题:

$$\min_{w^{(h)}} e = \sum_{i=1}^n \left[r_{i0} \sum_{t=1}^T \left(l_{it} - \sum_{h=1}^q w^{(h)} \hat{l}_{it}^{(h)} \right)^2 \right] \quad (1)$$

$$\sum_{h=1}^q w^{(h)} = 1, w^{(h)} \geq 0, \quad h = 1, 2, \dots, q$$

式中: l_{it} 为第 i 日第 t 时刻的历史负荷; $\hat{l}_{it}^{(h)}$ 为第 i 日第 t 时刻第 h 种方法的虚拟预测负荷; r_{i0} 为第 i 日与待预测日的特征量的相似度, r_{i0} 中已综合考虑了星期类型、日期差、气象参数等各种因素,因此,这种加权优化模型的含义非常明确:对于与待预测日的特征量相似程度较高的历史日的虚拟预测结果,应该在综合模型中取较大的权重; $w^{(h)}$ 为第 h 种方法在综合模型中的权重。

详细的推导过程见文献[2],此处不再赘述。

通过求解式(1)所示的非线性规划问题,即目标函数是虚拟预测残差平方和最小,得到各种预测方法的 $w^{(h)}$,因此,待预测日的预测结果是:

$$\hat{l}_{it} = \sum_{h=1}^q (w^{(h)} \hat{l}_{it}^{(h)}) \quad (2)$$

式中: $\hat{l}_{it}^{(h)}$ 为待预测日第 t 时刻第 h 种方法的虚拟预测负荷; \hat{l}_{it} 为待预测日第 t 时刻的负荷。

3 基于扰动思想的训练算法

3.1 扰动算法流程

扰动算法的基本思想是在每次迭代中让 B 的一个分量产生正负扰动,然后判断在扰动之后的映射表的预测效果。在正扰动、不扰动和负扰动 3 者中,取预测效果最佳者为下一次的解向量,依此类推。可以描述如下:

a. 设相关因素映射后的矩阵 B 的初值是 $B^{(0)}$, $B^{(0)}$ 可以按某种规则产生,也可从用户的数据库中读出,即: $b_{11}^{(0)}, b_{12}^{(0)}, \dots, b_{1i}^{(0)}, b_{21}^{(0)}, b_{22}^{(0)}, \dots, b_{2i}^{(0)}, \dots, b_{m1}^{(0)}$,

$b_{m2}^{(0)}, \dots, b_{mm}^{(0)}$,令训练次数计数器 $p=0$,求 $B^{(0)}$ 的预测效果 f_{opt} 。

b. 相关因素计数器 $k=1$ 。

c. 第 k 个相关因素映射表分段计数器 $j=1$ 。

d. 令 $\Delta B' = (0, 0, \dots, b_{kj}^{(p)} \gamma, \dots, 0)$, $\Delta B'' = (0, 0, \dots, b_{kj}^{(p)} / \lambda, \dots, 0)$,这里 γ, λ 均为大于 1 的正数,表示每次修正的步长。分别求取 $B' = B^{(p)} + \Delta B'$ 和 $B'' = B^{(p)} + \Delta B''$ 的预测效果 f', f'' ;记录 f', f'' 和 f_{opt} 中最优的为新的 f_{opt} ,所对应的决策变量为 $B^{(p+1)}$ 。

e. 判断 $j \geq l_k$?若是,则进入步骤 f;否则, $j=j+1$,转步骤 d。

f. 判断 $k \geq m$?若是,则 $p=p+1$,执行步骤 g;否则, $k=k+1$,转步骤 c。

g. 判断计算精度是否达到收敛(一般可以设定初始目标值的若干较小倍数)?若是,则执行步骤 i;否则,执行步骤 h。

h. 判断 $p > P_{max}$ (P_{max} 为最大训练迭代次数)?若是,则执行步骤 i;否则,转步骤 b。

i. 输出最终经过优化训练的映射表。

3.2 扰动算法分析

显然,扰动算法很容易编程实现,而且思路清晰。扰动算法相当于在由映射表中所有因素的映射后取值所构成的高维空间中,每次沿其中一个轴产生正、负方向的扰动。若某个扰动有效(优于原解),则接受该扰动,再试探下一个数轴;若该扰动无效,则在原来解的基础上再试探下一个数轴。这种方法可求得比初始解更好的解,但未必是全局最优解,相反,这种方法很容易陷入局部最优。同理,这种方法的搜索空间有限,尤其当相关因素的数目很多时,它的搜索效率比较低,这在后面的算例中可以看到。

近几年来,遗传算法[6]在很多领域得到广泛应用。遗传算法和其他搜索方法相比,其优越性主要表现在以下几个方面:①遗传算法在搜索过程中不易陷入局部最优,即使在所定义的适应度函数非连续、不规则和伴有噪声的情况下也能以极大的概率找到全局最优解;②由于遗传算法固有的并行性,使得它非常适合大规模并行分布处理;③遗传算法易于和别的技术(如神经网络、模糊推理、混沌行为和人工智能等)相结合,形成性能更优的问题求解方法。

基于以上分析,本文进一步提出利用遗传算法训练相关因素的新思路,在计算时间一定的情况下,提高了虚拟预测精度和实际预测精度。

4 基于遗传算法的训练方法

遗传算法本质是一种求解问题的高效并行全局搜索方法,与传统的求解优化问题的方法相比,如最

速下降法、Newton 法、BFGS 法等,它不需要知道目标函数的解析表达式等相关信息,并能全局收敛。利用遗传算法训练相关因素的具体描述如下。

4.1 算法步骤

该算法步骤为:①生成初始种群(本文取种群规模为 30);②进行虚拟预测,计算每一代染色体适应度;③选择操作;④交叉操作;⑤变异操作,生成新一代染色体;⑥判断是否达到终止代数,如果达到则退出;否则转到②。

4.2 编码方式

根据文献[1]提出的处理相关因素的策略,映射后向量 b_k 中的各元素 b_{kj} 均要求大于 0,一般在区间 $[0,1]$ 中。因此,遗传算法的编码方式采用实数编码,其优点是可以直接对解的数值进行遗传操作,染色体 (C_α) 中的基因 $(C_{\alpha\beta})$ 与相关因素映射后的取值一一对应,即 $b_{kj} \leftrightarrow C_{\alpha\beta}$ 。其中: $b_{kj} \in \{b_{11}, b_{12}, \dots, b_{1l_1}, b_{21}, b_{22}, \dots, b_{2l_2}, \dots, b_{m1}, b_{m2}, \dots, b_{ml_m}\}$; $\alpha \in [1, S]$ (α 是正整数); $\beta = l_1 + l_2 + \dots + l_{k-1} + j$; S 为种群规模; α 为种群中染色体的下标; β 为染色体中基因的下标。

4.3 评价函数

本文采用虚拟预测精度作为评价染色体优劣的依据。评价过程实质是一次虚拟预测的过程。首先调用各种单一预测方法对历史上某段日期进行虚拟预测,然后根据不同方法的权重调用综合模型对同一段日期进行虚拟预测,最终得到该段日期的虚拟预测负荷。通过比较虚拟预测负荷与历史负荷判断染色体的优劣。

这里取虚拟预测负荷与真实历史负荷的平均偏差率作为优化的目标函数,即:

$$f = \frac{1}{TI} \sum_{i=1}^I \sum_{t=1}^T \frac{|l_{it} - \hat{l}_{it}|}{l_{it}} \quad (3)$$

式中: I 是虚拟预测的天数。

4.4 交叉算子

在遗传算法中,交叉算子的设计是关键一步,本文采用算术交叉方式。步骤如下:首先生成一个 $[0,1]$ 内随机数 r ,设两个父代染色体是 $C_u^{(g)}, C_v^{(g)}$; 两个子代染色体是 $C_u^{(g+1)}, C_v^{(g+1)}$ (g 代表进化代数; u, v 代表种群中染色体的下标),则两个子代染色体的第 β 个基因可以表示为:

$$\begin{cases} C_{u\beta}^{(g+1)} = r C_{u\beta}^{(g)} + (1-r) C_{v\beta}^{(g)} \\ C_{v\beta}^{(g+1)} = r C_{v\beta}^{(g)} + (1-r) C_{u\beta}^{(g)} \end{cases} \quad (4)$$

4.5 变异算子

本文采用一致性变异方式。步骤如下:首先令 $N_{inf} = 10$,并生成一个 $[-1,1]$ 内的随机向量 d ,设 $C_\alpha^{(g)}$ 是变异前的染色体, $C_\alpha^{(g+1)}$ 是变异后的染色体,

则变异后染色体的第 β 个基因可以表示为:

$$C_{\alpha\beta}^{(g+1)} = C_{\alpha\beta}^{(g)} + N_{inf} d_\beta \quad (5)$$

式中: d_β 代表随机向量 d 第 β 个分量。

当 $C_\alpha^{(g+1)}$ 中某个基因不在 $[0,1]$ 范围之内时,令 $N_{inf} \in [0, N_{inf}]$,再次计算式(5),直到 $C_\alpha^{(g+1)}$ 中每一个基因均满足约束条件为止。

5 算例分析

下面通过算例分析本文提出的两种训练算法的有效性,并且比较它们各自的特点。

为了分析的方便,本文以一星期连续 7 d 负荷预测的结果为例。这里采用某省 2001 年 12 月至 2002 年 1 月的负荷数据,对 2002 年 1 月 12 日至 2002 年 1 月 18 日的负荷进行预测,每日预测点数为 96 点。算例中映射库训练目标函数和实际预测的精度均以平均偏差率这一指标表示。综合模型采用的单一方法,包括 Arima 模型法、模式识别法、点对点倍比法、变化系数法、相似度外推法、一元线性回归法 6 种方法。

两种算法在分别计算 20 min 的情况下,目标函数数值比较如表 1 所示。初始目标值均为 0.046 011,计算机 CPU 为 P II 233 MHz,内存为 256 MB。

表 1 两种算法训练后的目标函数数值比较
Table 1 Objectives trained by two methods respectively

算法	计算代数	计算时间/s	目标函数值	目标函数改善率/(%)
摄动算法	摄动 5 000 次	1 200	0.026 848	41.6
遗传算法	进化 2 000 代	1 200	0.019 643	57.3

遗传算法训练 20 min 后(2 000 代,种群规模 30)目标函数的下降曲线如图 4 所示。

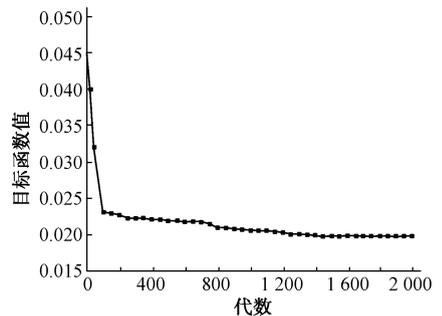


图 4 遗传算法目标函数变化曲线
Fig. 4 Objective variation trained by genetic algorithm method

在 3 种情况下(未训练、摄动算法训练 20 min 后和遗传算法训练 20 min 后),分别进行实际预测,各种预测结果的对比情况如表 2 所示,其中使用平均偏差率进行比较。

从表 2 的对比中可以看到,在相同条件下经过训练后的预测效果普遍优于未经训练的预测效果;采用遗传算法训练后的预测效果要优于摄动算法。训练精度的提高使得实际预测的精度更高,这正是文献[2]中提出的虚拟预测策略的体现。

表 2 各种条件下的预测效果比较
Table 2 Different forecasting results

日期	未训练	摄动算法训练	遗传算法训练
2002-01-12	2.128	2.082	1.986
2002-01-13	2.575	2.023	1.554
2002-01-14	2.677	2.366	2.197
2002-01-15	2.481	2.252	2.149
2002-01-16	1.836	2.074	1.656
2002-01-17	2.035	1.249	1.134
2002-01-18	1.959	2.196	2.281
累积平均偏差率	2.241	2.034	1.851

6 结语

通过以上试验数据的分析可以看出,训练相关因素库可以使得相关因素的量化映射值更加合理,从而使预测效果和稳定性进一步得到提高。如果能够搜集更加齐全的影响负荷的相关因素,通过基于虚拟预测思想的综合模型以及相关因素库训练算法可以比较好地根据不同地区、不同时期相关因素的情况调整映射后的取值,从而提高预测精度。本文提出的两种算法可以有效地训练短期负荷预测相关因素库,最终提高负荷预测精度,从而更好地为电力规划、电力市场等工程实践提供决策依据,同时,也为解决其他优化问题提供有益的思路。这两种算法的特点分别是:摄动算法思路简单清晰,易于编程实现,但是容易陷入局部最优解;遗传算法优化深度大,搜索空间广,目标函数下降快,但是编程的工作

量较大,而且初始种群具有随机性。

参考文献

- 康重庆,程旭,夏清,等(Kang Chongqing, Cheng Xu, Xia Qing, et al). 一种规范化的处理相关因素的短期负荷预测新策略(A New Unified Approach to Short-term Load Forecasting Considering Correlated Factors). 电力系统自动化(Automation of Electric Power Systems),1999,23(18): 32~35
- 程旭,康重庆,夏清,等(Cheng Xu, Kang Chongqing, Xia Qing, et al). 短期负荷预测的综合模型(Integrated Model of Short-term Load Forecasting). 电力系统自动化(Automation of Electric Power Systems),2000,24(9): 42~44
- Hiroyuki Mori, Atsushi Yuihara. Deterministic Annealing Clustering for ANN-based Short-term Load Forecasting. IEEE Trans on Power Systems, 2001, 16(3): 545~551
- 袁曾任(Yuan Zengren). 人工神经网络及其应用(Application of Artificial Neural Network). 北京:清华大学出版社(Beijing: Tsinghua University Press),1999
- 程旭(Cheng Xu). 基于模式识别的短期负荷预测自适应理论的研究;[硕士学位论文](Researches of Adaptive Short-term Load Forecasting Theories Based on Pattern Recognition, Thesis). 北京:清华大学(Beijing: Tsinghua University),2000
- 陈国良,王煦法,庄镇泉,等(Chen Guoliang, Wang Xufa, Zhuang Zhenquan, et al). 遗传算法及其应用(Application of Genetic Algorithm). 北京:人民邮电出版社(Beijing: People Posts and Telecommunications Publishing House),1996
- 邓聚龙(Deng Julong). 灰色预测与决策(Gray Prediction and Decision). 武汉:华中工学院出版社(Wuhan: Huazhong Institute of Technology Press),1986

高峰(1977—),男,硕士研究生,从事电力市场的研究。E-mail: gaof00@mails.tsinghua.edu.cn

康重庆(1969—),男,博士,副教授,研究方向包括电力市场、电力系统规划、电力经济与信息技术、负荷预测等。E-mail: cqkang@tsinghua.edu.cn

程旭(1977—),男,硕士,从事电力市场的研究。

ADAPTIVE TRAINING APPROACHES CONSIDERING IMPACT FACTORS IN SHORT-TERM LOAD FORECASTING

Gao Feng, Kang Chongqing, Cheng Xu, Shen Yu, Xia Qing, Peng Tao, Zhou Anshi
(Tsinghua University, Beijing 100084, China)

Abstract: To improve prediction precision is the most radical objective in short-term load forecasting (STLF). On the basis of the presented unified approach considering load-relative factors and integrated model of STLF, the idea of adaptive training is used to deal with load-relative factors in STLF. The concept of adaptive training of load-relative factors is proposed and studied in the paper. Some basic questions about adaptive training are analyzed and an abstract model describing the progress of STLF is presented. Moreover, two kinds of training methods, perturbation algorithm and genetic algorithm, are both proposed to optimize the load-relative factors. The advantages and disadvantages of both methods are illustrated. Case study shows that the precision of STLF has been improved apparently after load-relative factors have been trained.

This project is supported by National Key Basic Research Special Fund of China (No. G1998020311).

Key words: short-term load forecasting (STLF); virtual forecasting; load-relative factors; integrated model; perturbation algorithm; genetic algorithm