

基于小波变换和混合神经网络的短期负荷预测

尹成群,康丽峰,李 丽,王红云

(华北电力大学 电子与通信工程系,河北 保定 071003)

摘要: 提出通过小波分解对各负荷子序列进行特性分析初选影响因素后,采用信息熵法从初选变量中自动筛选出对负荷较重要的因素,然后采用改进的主成分分析法消除重要影响因素间的相关性,采用动态聚类法对各分解序列的样本归类,通过灰色关联分析选择出与预测时刻负荷模式最相似的类作为神经网络训练的典型样本集,采用蚁群优化算法训练各子序列相应神经网络模型,采用小波重构得到最终负荷预测结果。并利用某地区 1999 年的实际负荷对所提方法进行验证,结果表明了该方法的合理性和有效性。

关键词: 负荷预测; 小波变换; 信息熵; 主成分分析; 动态聚类法; 蚁群优化算法

中图分类号: TM 715

文献标识码: A

文章编号: 1006-6047(2007)05-0040-05

0 引言

短期负荷预测在电力系统安全稳定经济运行中起着非常重要的作用。准确的负荷预测将直接影响电力系统的经济效益。据估计,1%的预测误差将会导致一年中百万英镑的经济损失。

根据短期电力负荷的特性,负荷信号一般表现为连续频谱,在一段连续波动过程中,呈现瞬变非周期性,而小波变换具有自适应可调时频窗特点,因此是研究负荷特性的重要而有效的工具。

文献[1-3]中采用小波分解和神经网络相结合的预测模型比仅采用神经网络的预测模型精度有所提高,但是由于它们都只是根据小波分解后各子序列的负荷特性按照经验粗略选择负荷的相关影响因素,因此有些选择的影响因素可能对负荷影响也不是很大,而且彼此间还有可能存在相关性。针对此问题,文中除了通过小波分解对负荷特性分析外,还采用了无需任何先验经验而完全依赖于数据的信息熵法从初选变量中自动筛选出对负荷较重要的因素,然后采用改进的主成分分析法消除重要影响因素间的相关性。

另外,对于神经网络预测模型,典型样本的选择也很关键。但文献[1-3]中并没有提出更为有效的样本选择方法。一般,样本选择应满足强相关、相似和适量的原则。如果训练样本太多,就会增加训练时间;而训练样本太少,又不能遍历所有可能的负荷模式,不具有典型性。故此处先采用动态聚类法对所有样本聚类,然后通过灰色关联分析选择出与预测时刻负荷模式最相似的类作为神经网络训练的典型样本集。

对于学习算法,如果仍然采用最常用的 BP 算法,就会限制所建模型的优点,因而,采用了具有正反馈、分布式计算和启发性收敛特点的蚁群优化(ACO)算法,从而提高了预测模型的全局搜索能力和泛化能力。

最后,应用 1999 年某地区实际负荷对所建模型进行测试,结果表明了所提方法的合理性和有效性。

1 预测模型建立

1.1 日负荷数据的小波分解

电力负荷的变化规律主要包含 2 种趋势:一是逐渐增长的趋势,二是以日、周、月、年为周期的波动趋势,故很难用一个精确的数学表达式描述。通过小波变换^[1-4]则可以把负荷中的随机高频分量和线性分量明显分开,从而分别对各自的特性进行分析。

双正交小波具有很好的对称性及线性相位,在小波分解和重构时不容易发生失真。另外,尺度的合理选择也很关键。经研究表明,将负荷数据分解至尺度 3 是比较合理的。故采用双正交样条小波 bior 5.5 对某地区 1999 年 4 月份最后 2 周的负荷数据序列分解至尺度 3,以 1 h 为时间间隔进行采样,1 日采样 24 点,2 周共采样 $24 \times 14 = 336$ 点。图 1 所示为原始负荷序列及小波分解系数。

在图 1 中, a_0 表示原始序列($a_0 = a_3 + d_3 + d_2 + d_1$), a_3 表示序列的低频部分(近似部分),具有了光滑特性,保持了原序列的曲线形状,具有日、周周期性。 d_3 、 d_2 、 d_1 是序列的高频部分(细节部分)。其中, d_3 基本上具有隐藏的半日周期性。 d_2 中,负荷的日周期内嵌 4 个短周期,说明该地区负荷序列每天出现 4 次稳定的耗电量波动。研究表明, d_2 的预测采用和 d_3 相同的模型能得到较好的预测精度。 d_1 主要表现

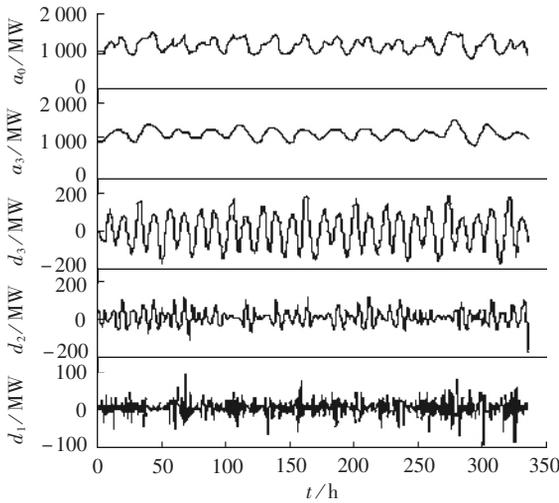


图 1 2 周负荷序列分解

Fig.1 Decomposition of two-week load sequence

为随机负荷分量,具有短时依赖关系。另外,考虑到不同日类型对负荷影响也比较大,用 $l(i, t)$ 表示第 i 日第 t 时刻的负荷值, $D(i)$ 代表第 i 日的日类型,分析影响各负荷子序列的因素。

a. 影响 a_3 的因素: $l(i-21, t)$ 及前后各 3 个时刻的负荷; $l(i-14, t)$ 及前后各 3 个时刻的负荷; $l(i-7, t)$ 及前后各 3 个时刻的负荷; $l(i-3, t)$ 及前后各 3 个时刻的负荷; $l(i-2, t)$ 及前后各 3 个时刻的负荷; $l(i-1, t)$ 及前后各 3 个时刻的负荷; $l(i, t-1)$ 、 $l(i, t-2)$ 、 $l(i, t-3)$; $D(i)$ 、 $D(i-1)$ 、 $D(i-2)$ 、 $D(i-3)$ 。

b. 影响 d_3 、 d_2 的因素: $l(i, t-12)$ 、 $l(i-1, t-12)$ 、 $l(i-2, t-12)$ 及 a_3 中的影响因素。

c. 影响 d_1 的因素: 前 24 h 的负荷值以及 $D(i)$ 、 $D(i-1)$ 。

可以看出,各负荷子序列的影响因素虽然全面但是数量较多。以预测 4 月 30 日为例,通过对 d_2 序列的相关性分析可知,任意 2 个变量之间的相关性最大为 0.9659,最小为 0.0017,所以属性约简是有必要的。

1.2 影响因素的约简

1.2.1 信息熵理论

信息熵约简法是一种将粗集论与信息论相结合的属性约简法,利用条件熵确定决策属性对某一条件属性的依赖性。假设信息系统 $S = \langle U, A \rangle$, U 为论域, A 为条件属性集 C 和决策属性集 D 的集合, a_i 为某一条件属性,则决策属性 D 对某一条件属性 a_i 的依赖程度可以利用下式计算^[5-7]:

$$I(a_i, D) = \left[H\left(\frac{R_D}{R_{C-a_i}}\right) - H\left(\frac{R_D}{R_C}\right) \right] / H\left(\frac{R_D}{R_C}\right) \quad (1)$$

其中, R_C 、 R_D 分别表示条件属性集 C 和决策属性集 D 在论域上的等价关系; $H(R_D/R_C)$ 表示 R_D 相对于 R_C 的条件熵。 $I(a_i, D)$ 的值越大,条件属性 a_i 对决策属性 D 的重要性越大。如果 $I(a_i, D) = 0$,则说明 a_i 对于 D 不起作用,可以删除。在信息熵约简法中一般要设定一个重要性阈值,大于这一阈值的属性认

为是对负荷影响较大的因素,而小于这一阈值的属性则认为冗余的,可以删除。

对 4 月 30 日的子序列 d_2 ,信息熵法约简的阈值设定为 0.1。经约简后,影响因素从原来的 52 个减少为 23 个。对这 23 个变量计算互相关系数可知,其相关性仍然存在,所以可以在保证绝大部分信息不丢失的情况下对这些变量继续进行约简,从而消除它们之间的相关性。

1.2.2 主成分分析法

主成分分析法是研究多个数值变量间相关性的一种多元统计方法。在基本保持原变量信息不变的前提下,能通过少数几个互不相关新变量的线性组合代替原变量并揭示原变量之间的关系,是消除相关性的有效手段。下面描述其具体的实现过程^[8-10]。

假设原有 p 个彼此相关的负荷影响因素,则训练样本构成的数据矩阵为 X 。设 $X = [x_1, x_2, \dots, x_p]^T$, 则求 X 的各主成分就等价于求其相关矩阵的大于 0 的各特征值及相应的单位正交特征向量 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$ 及 $d = [d_1, d_2, \dots, d_p]$ 。定义 $Y = [Y_1, Y_2, \dots, Y_p]^T$ 为主成分向量,则

$$Y = d^T X^* \quad (2)$$

式中 X^* 表示 X 经过标准差标准化方法规范化后的数据矩阵。

选择 $m (m < p)$ 主成分,前面 m 主成分的累计方差和占全部总方差的比例为

$$\alpha = \frac{\sum_{i=1}^m \lambda_i}{\sum_{i=1}^p \lambda_i} \quad (3)$$

如果 α 接近 1,就用这 m 主成分 Y_1, Y_2, \dots, Y_m 代替原始变量 x_1, x_2, \dots, x_p 。

传统的标准化方法使各维指标的方差均为 1,消除了各维指标在变异程度上的差异,却使从中提取的主成分只包含了各维指标间的相互影响这一部分信息,不能准确反映原始数据所包含的全部信息。故采用如下的改进公式对负荷数据进行标准化处理^[11]:

$$x_{ij}^* = \frac{x_{ij}}{E(x_i)} \quad i=1, 2, \dots, N; \quad j=1, 2, \dots, p \quad (4)$$

对 4 月 30 日的 d_2 序列采用改进的主成分分析法约简后,剩余 7 个重要的负荷影响因素。这时选择出的因素既对负荷影响较大,而且数量也较少。

1.3 训练样本的选择

为保证足够的数量,选择预测日前 2 个月的历史负荷数据作为训练样本备选集。根据某种相似性将所有样本进行分类,与预测时刻负荷模式最相似的类即为该时刻模型的训练样本集。根据样本间的某种相似性自动实现输入空间划分最好的工具是聚类分析^[12-13]。但是对于一般聚类的方法,比如 K -均值、自组织映射法都需要给出初始聚类数目和聚类中心,而聚类数目的确定存在很大的经验因素,所以如果初始分类不好,最后的聚类结果就会受到影响。层次聚类的思想虽然效果较好,但计算量较大,所需的聚类时间较长,故在此采用了一种既可以由

少到多自动聚类,计算量又不是很大的聚类方法——动态聚类法。

设预测日的 M 个样本经动态聚类后的类别数为 N ,则每个类别 s 的歪定义为

$$D(s) = \min \{ D(x, s) | x \in V \} \quad (5)$$

$$D(x, s) = \sum_{y \in s} d(x, y)$$

式中 x, y 是空间 V 中任意 2 点。

N 个类别的总歪为

$$D(S) = \sum_{n=1}^N D(s_n) \quad (6)$$

每个样本模式类 s 的圆心 z_n 为

$$z_n = \frac{1}{J_n} \sum_{j=1}^{J_n} x_j^{(n)} \quad (7)$$

式中 $x_j^{(n)} (j=1, 2, \dots, J_n)$ 为 s_n 中所有的样本。

下面分析动态聚类算法的学习过程^[14]。

a. 初始化: 设定一个合适的 r 并置初始聚类数 $k=1$, 初始聚类重心 z_1 为第 1 个输入样本。

b. 依次计算第 $i=2, 3, 4, \dots, N$ 样本与已有的 k 聚类重心之间的最小距离 r_{ij} 。如果 $r_{ij} > r$, 则聚类数 $k=k+1$, 第 i 个样本成为第 $k+1$ 类的聚类重心; 否则第 i 个样本属于第 j 类, 该类重心变为 $z_j = \frac{1}{m} \sum_{j=1}^m x_j$, m 表示第 j 类中的样本个数。

c. 计算对应的总歪 $D(S)$ 。若 $D_r'(S) - D_r(S) < \varepsilon$ ($D_r'(S)$ 是上次的总歪), 转至 **d**, 否则转至 **a**。

d. 停止计算, 此时 k 值为相应的模式聚类数, $z_j (j=1, 2, \dots, k)$ 为相应的聚类重心。

以经验公式(8)作为选取最优聚类数和最佳 r 值的标准。

$$K = \max \left\{ \frac{D(k)}{k/(k-1)} \mid k=2, 3, \dots, N \right\} \quad (8)$$

式中 K 为选择标准; k 为相应的聚类数; $D(k)$ 为对应的总歪。

当 K 第 1 次达到最大值时对应的情况就是聚类程度较稳定的最优聚类。

对于 4 月 30 日的 d_2 序列采用动态聚类法确定最佳间距 r 和最佳聚类数目 k 的过程如表 1 所示。

由表 1 可以看出, 最佳的 r 为 2.7, 最佳的 k 为 7。

表 1 最佳的 r 和聚类数 k

Tab.1 Optimal r and clustering number k

r	K	k	r	K	k
1.4	717.6	59	2.6	1110.7	7
1.5	765.6	46	2.7	1119.5	7
1.6	796.9	37	2.8	1110.4	6
1.7	843.6	31	2.9	1119.8	5
1.8	873.9	26	3.0	1119.8	5
1.9	931.3	19	3.1	1080.3	4
2.0	971.5	16	3.2	1083.1	4
2.1	988.0	12	3.3	1083.1	4
2.2	1010.0	11	3.4	1094.9	4
2.3	1023.9	9	3.5	1012.3	3
2.4	1062.9	9	4.0	934.9	2
2.5	1084.9	9	5.7	-	1

1.4 神经网络模型

电力负荷预测应用最为广泛的是 BP 网络, 但是 BP 网络具有收敛速度慢、易陷入局部最小的缺陷。为了克服这些缺陷, 在此采用 ACO 算法作为学习算法。ACO 的正反馈特性使得收敛速度加快, 分布式计算特性避免了收敛过程中出现早熟现象而陷入局部最优, 启发性收敛特性则使搜索过程中更早发现可接受解成为可能。下面描述 ACO 算法应用于神经网络的基本过程^[15]。

假设 m 代表网络中总参数的个数, 包括所有权重和阈值在内。 h 代表蚂蚁数, 则 h 的取值一般与 m 接近或略高于 m 。对于每个参数, 在 $[-1, 1]$ 之间随机初始化为 N 个可能解, 第 i 个参数的解集合设为 $I_{pi} (1 < i < m)$, $\tau_j(I_{pi})(t)$ 表示 t 时刻集合 I_{pi} 中第 j 个元素的信息素。则蚂蚁寻找食物的过程就可以看作是分别从各个解集合中选出一个参数取值的过程。至于每个参数取值的选择, 在此根据式(9)计算出的概率实施轮盘赌法:

$$P(\tau_j^k(I_{pi})) = \tau_j(I_{pi}) / \sum_{g=1}^N \tau_g(I_{pi}) \quad (9)$$

用 h 只蚂蚁分别寻找食物, 从而得到 h 种网络参数解的方案, 选择使得预测误差最小的一组解, 如果与以前相比, 进化程度不是很大或迭代次数已经达到最大值, 则迭代结束, 输出最优解。如果任意一个条件都不满足, 则对各解集合中的每一个元素根据式(10)(11)调整信息素:

$$\tau_j(I_{pi})(t+m) = \rho \tau_j(I_{pi})(t) + \Delta \tau_j(I_{pi}) \quad (10)$$

$$\Delta \tau_j(I_{pi}) = \sum_{k=1}^h \Delta \tau_j^k(I_{pi}) \quad (11)$$

式中 ρ 是信息残留度, 取值在 $[0, 1]$ 之间。

$\Delta \tau_j^k(I_{pi})$ 表示第 k 只蚂蚁在本次迭代中在集合 I_{pi} 中第 j 个元素上留下的信息素, 可用下式计算:

$$\Delta \tau_j^k(I_{pi}) = \begin{cases} \frac{Q}{e^k} & \text{如果本次循环中第 } k \text{ 只蚂蚁} \\ & \text{选择了 } I_{pi} \text{ 中的第 } j \text{ 个元素} \\ 0 & \text{其他} \end{cases} \quad (12)$$

式中 Q 是常数, 用作调整信息素的调整速度, 一般取值范围比较大, 要经过多次试验调整确定; e^k 是第 k 只蚂蚁选择的一组解作为网络参数时的最大输出误差。

2 实例分析

以某地区 1999 年 4 月 30 日的历史负荷数据为例, 对所提方法的性能进行验证。

为了保证一定的数据量, 选择离预测日最近 2 个月的负荷作为训练样本备选集。采用双正交小波 bior 5.5 将这 2 个月的负荷数据序列分解至尺度 3, 得到的负荷子序列 a_3, d_3, d_2, d_1 如前文所述。

根据 a_3, d_3, d_2, d_1 各序列的特性初选出的影响因素分别为 49、52、52、26, 经信息熵约简后的变量个数分别为 6、4、23、3, 再经主成分分析法约简后的变量个数分别为 4、3、7、3, 信息熵法约简时的重要性阈值均为 0.1, 主成分分析法中方差累积贡献率的阈值为

95%。各子序列的预测分别采用相应的 3 层 BP 网络模型,其中隐含层神经元按下式初步确定^[16]:

$$s = \sqrt{m+n} + a \quad a \in (1, 10) \quad (13)$$

然后经多次实验调整最终确定,最后得到的网络结构分别为 4-4-1、3-5-1、7-6-1、3-5-1。

对各序列的样本动态聚类后得到的类别数分别为 13、9、9、11。采用灰色关联分析法选择出与预测时刻最相似的类作为该时刻的训练样本集,并通过 ACO 算法不断调整网络参数,各子序列 ACO 算法的参数取值分别为: ρ 均为 0.7, Q 分别为 10、10、30、10, N 均为 100, h 均为 50, 迭代次数分别为 30、50、30、30。最终得到各子序列预测值与实际值对比结果见图 2。将各预测值叠加后的日负荷预测值(曲线 1)与实际值(曲线 2)对比见图 3。

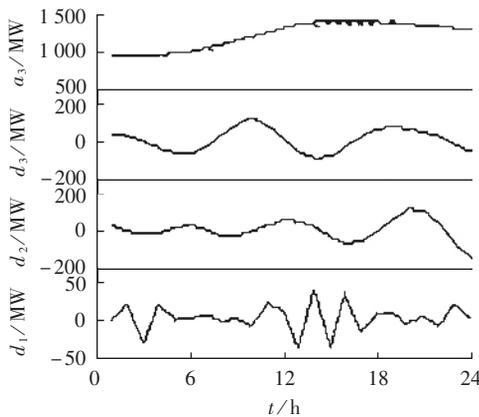


图 2 分解序列及其预测值

Fig.2 Decomposed series and their forecasted values

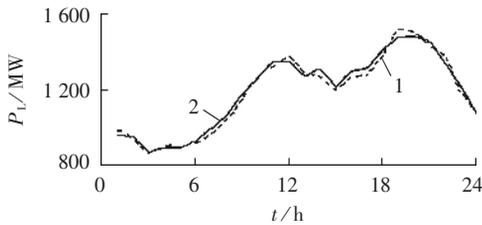


图 3 日负荷预测值与实际值的对比

Fig.3 Comparison between forecasted and actual values of daily load

另外,还从平均绝对百分误差(MAPE)、均方根误差(RMSE)和最大相对误差(MAX)的角度,将本文方法与采用小波分解和无数据预处理的 BP 网络模型(模型 1)以及采用小波分解、数据预处理和 L-M 算法的 BP 网络模型(模型 2)的预测结果进行了对比,比较结果如表 2 所示。表 3 为 3 种方法对 1 周负荷预测结果的对比。

从图 2、图 3、表 2 和表 3 可以看出,所提出的对小波分解后的负荷序列相继采用信息熵和主成分分析法进行变量选择,动态聚类 and 灰色关联分析结合进行样本选择,ACO 算法训练相应 BP 网络模型的方法比不采用数据预处理或 ACO 算法的 BP 网络模型预测精度要高,而且不易陷入局部最小,提高了全局搜索能力和泛化能力。

表 2 3 种方法的误差比较

Tab.2 Error comparison among three methods

方法	RMSE	MAPE	MAX
1	2.013 4	1.712 5	4.211 9
2	1.758 4	1.492 2	3.579 9
3	1.311 5	1.098 1	2.465 3

注:方法 1~3 分别指模型 1、模型 2 及本文方法;后同。

表 3 3 种方法对 1 周负荷预测误差的比较

Tab.3 Forecast errors of three methods for a week

日期	方法	RMSE	MAPE	日期	方法	RMSE	MAPE
4-23	1	2.484 2	1.860 9	4-27	1	1.921 1	1.556 2
	2	1.684 2	1.265 3		2	1.735 9	1.371 7
	3	1.034 9	0.784 7		3	1.392 6	1.076 1
4-24	1	1.801 7	1.499 1	4-28	1	1.755 5	1.249 7
	2	1.542 8	1.256 1		2	1.545 0	1.179 0
	3	1.291 0	0.994 4		3	1.067 6	0.919 1
4-25	1	2.066 6	1.581 4	4-29	1	1.682 8	1.345 1
	2	1.696 3	1.330 8		2	1.408 3	1.040 9
	3	1.527 6	1.188 0		3	0.996 7	0.924 5
4-26	1	1.859 4	1.349 0				
	2	1.776 7	1.441 2				
	3	1.130 1	0.808 6				

3 结论

a. 信息熵和主成分分析法相结合的约简方法在小波分解后特性分析的基础上,更进一步选择出了与负荷相关性很大而彼此之间无关性的变量。

b. 动态聚类和灰色关联分析法结合,有效地选择出了与预测时刻负荷模式相似的典型样本,缩短了训练时间,易于收敛。

c. ACO 算法的引入,提高了全局搜索能力和泛化能力。

d. 通过实际负荷数据对提出模型的验证,证明了所提方法的预测精度较高。

参考文献:

- [1] 宋超,黄民翔,叶剑斌. 小波分析方法在电力系统短期负荷预测中的应用[J]. 电力系统及其自动化学报,2002,14(3):8-12. SONG Chao,HUANG Min-xiang,YE Jian-bin. The application and problems of wavelets used in short-term power load forecasting[J]. Proceedings of the EPSA,2002,14(3):8-12.
- [2] 徐军华,刘天琪. 基于小波分解和人工神经网络的短期负荷预测[J]. 电网技术,2004,28(8):30-33. XU Jun-hua,LIU Tian-qi. An application to short-term load forecasting based on wavelet transform and artificial neural network[J]. Power System Technology,2004,28(8):30-33.
- [3] 邵能灵,侯志俭. 小波模糊神经网络在电力系统短期负荷预测中的应用[J]. 中国电机工程学报,2004,24(1):24-29. TAI Neng-ling,HOU Zhi-jian. A new short-term load forecasting principle with the wavelet transform fuzzy neural network for the power systems[J]. Proceedings of the CSEE,2004,24(1):24-29.
- [4] 张大海,江世芳. 基于小波包分析的电力负荷预测算法[J]. 电力系统及其自动化学报,2004,16(2):51-53,84. ZHANG Da-hai,JIANG Shi-fang. Power load forecasting

- algorithm based on wavelet packet analysis[J]. Proceedings of the EPSA, 2004, 16(2): 51-53, 84.
- [5] 程其云, 孙才新, 周淙, 等. 粗糙集信息熵与自适应神经网络模糊系统相结合的电力短期负荷预测模型及方法[J]. 电网技术, 2004, 28(17): 72-75.
CHENG Qi-yun, SUN Cai-xin, ZHOU Quan, et al. Model and method for power system short-term load forecasting based on integration of information entropy in rough set theory with adaptive neural fuzzy inference system[J]. Power System Technology, 2004, 28(17): 72-75.
- [6] 钟波, 周家启, 肖智. 基于粗糙集和神经网络的电力负荷新型预测模型[J]. 系统工程理论与实践, 2004(6): 113-119.
ZHONG Bo, ZHOU Jia-qi, XIAO Zhi. A new power load forecasting model based on rough set and artificial neural network[J]. Systems Engineering—Theory & Practice, 2004(6): 113-119.
- [7] 王国胤. Rough 集理论与知识获取[M]. 西安: 西安交通大学出版社, 2001.
- [8] 柳进, 唐隆龙. 基于主成分分析 L-M 神经网络高峰负荷预测研究[J]. 继电器, 2004, 32(13): 24-27.
LIU Jin, TANG Jiang-long. Peak load forecasting based on neural network with principal component analysis[J]. Relay, 2004, 32(13): 24-27.
- [9] 王志征, 余岳峰, 姚国平. 主成份分析法在电力负荷预测中的应用[J]. 电力需求侧管理, 2003, 5(3): 21-24.
WANG Zhi-zheng, YU Yue-feng, YAO Guo-ping. The application of principal component analysis in load forecasting[J]. Power DSM, 2003, 5(3): 21-24.
- [10] 赵杰辉, 葛少云, 刘自发. 基于主成分分析的径向基函数神经网络在电力系统负荷预测中的应用[J]. 电网技术, 2004, 28(5): 35-37, 40.
ZHAO Jie-hui, GE Shao-yun, LIU Zi-fa. Application of radial basic function network based on principal component analysis in load forecasting[J]. Power System Technology, 2004, 28(5): 35-37, 40.
- [11] 程其云, 王有元, 陈伟根. 基于改进主成分分析的短期负荷预测方法[J]. 电网技术, 2005, 29(3): 64-67.
CHENG Qi-yun, WANG You-yuan, CHEN Wei-gen. Modified principal component analysis based short-term load forecasting [J]. Power System Technology, 2005, 29(3): 64-67.
- [12] 赵剑剑, 张步涵, 程时杰, 等. 一种基于径向基函数的短期负荷预测方法[J]. 电网技术, 2003, 27(6): 22-25, 32.
ZHAO Jian-jian, ZHANG Bu-han, CHENG Shi-jie, et al. A deterministic annealing clustering based short-term load forecasting method with radial basis function network[J]. Power System Technology, 2003, 27(6): 22-25, 32.
- [13] 赵菁, 彭慧敏, 张家亮, 等. 基于自组织特征映射神经网络的短期负荷预测[J]. 贵州工业大学学报: 自然科学版, 2003, 32(2): 57-62.
ZHAO Jing, PENG Hui-min, ZHANG Jia-liang, et al. Short-term load forecasting based on self-organizing feature mapping neural network[J]. Journal of Guizhou University of Technology: Natural Science, 2003, 32(2): 57-62.
- [14] 惠兰, 安敏, 刘晓津, 等. 基于动态聚类算法径向基函数网络的配电网线损计算[J]. 中国电机工程学报, 2005, 25(10): 35-39.
HUI Lan, AN Min, LIU Xiao-jin, et al. The calculation of energy losses in distribution systems based on RBF network with dynamic clustering algorithm[J]. Proceedings of the CSEE, 2005, 25(10): 35-39.
- [15] 邹政达, 孙雅明, 张智晟. 基于蚁群优化算法递归神经网络的短期负荷预测[J]. 电网技术, 2005, 29(3): 59-63.
ZOU Zheng-da, SUN Ya-ming, ZHANG Zhi-sheng. Short-term load forecasting based on recurrent neural network using ant colony optimization algorithm[J]. Power System Technology, 2005, 29(3): 59-63.
- [16] ZHANG Yun, HE Yong. Study of prediction model on grey relational BP neural network based on rough set[C]//Proceedings of the Fourth International Conference on Machine Learning and Cybernetics. Guangzhou, China: [s.n.], 2005: 4764-4769.
(责任编辑: 李育燕)

作者简介:

尹成群(1953-), 男, 河北灵寿人, 教授, 研究方向为信号与信息处理;

康丽峰(1981-), 女, 河北万全人, 硕士研究生, 研究方向为电力负荷预测(E-mail: kanglifeng2000@126.com);

李丽(1982-), 女, 河北衡水人, 硕士研究生, 研究方向为数字水印;

王红云(1980-), 女, 河北故城人, 硕士研究生, 研究方向为单片机应用。

Short-term load forecast based on combination of wavelet transform and hybrid neural network

YIN Cheng-qun, KANG Li-feng, LI Li, WANG Hong-yun

(Department of Electronic and Communication Engineering, North China

Electric Power University, Baoding 071003, China)

Abstract: A hybrid load forecast method is put forward. The character analysis is carried out with wavelet decomposition for each load subsequence and influencing factors are thus determined, from which main factors are selected using the information entropy method and their relativity is eliminated using the improved principal component analysis method. The dynamic clustering analysis is used to divide the historical load data into several categories and the grey relative analysis to pick out one as the typical sample set, which is most similar to the forecasting load mode. The ant colony optimization algorithm is then used to train the corresponding neural network model of each decomposed subsequence and the wavelet reconstruction is used to achieve final forecasts. Actual loads of a district in 1999 are taken for verification, which shows the proposed method is rational and effective.

Key words: load forecast; wavelet transform; information entropy; principal component analysis; dynamic clustering algorithm; ant colony optimization algorithm