

文章编号: 1001-0920(2011)04-0519-05

基于动态模糊粒神经网络算法的负荷辨识

陶永芹^{1,2}, 崔杜武¹

(1. 西安理工大学 计算机科学与工程学院, 西安 710048; 2. 西安交通大学 计算机系, 西安 710049)

摘要: 针对电力负荷的时变、变结构和非线性等特点, 提出一种动态模糊粒神经网络算法. 该算法采用粒计算商空间理论和模糊神经网络技术对电力负荷进行建模. 将椭圆基函数和模糊 ζ^- 完备性作为在线参数分配机制, 避免了初始化选择的随机性. 根据模糊规则和输入变量的重要性, 对每条规则的输入变量宽度实施在线自适应调整, 从而实现了负荷参数和结构同时辨识. 实验结果表明了所提出方法的可行性和有效性.

关键词: 负荷模型; 参数辨识; 结构辨识; 粒计算; 动态模糊神经网络

中图分类号: TM714

文献标识码: A

Load identification of algorithm based on dynamic fuzzy granular neural network

TAO Yong-qin^{1,2}, CUI Du-wu¹

(1. School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China; 2. Department of Computer Science and Technology, Xi'an Jiaotong University, Xi'an 710049, China. Correspondent: TAO Yong-qin, E-mail: taoyongqin@mail.xjtu.edu.cn)

Abstract: An algorithm based on dynamic fuzzy granular neural network is proposed for the characteristics of power load, which is time-variant, variable structure and non-linear. The quotient space theory of granular computing and fuzzy neural network technology are used in power load modeling. Elliptic basis function and fuzzy ζ^- completeness are also used as a distribution mechanism of on-line parameter to avoid the randomness of the initialization options. Online self-adapting adjustment is executed on the width of input variable according to fuzzy rules and the importance of input variables, and then the load parameters and the structure can be identified synchronously. Experimental results show the feasibility and effectiveness of this method.

Key words: load model; parameter identification; constructure identification; granular computing; dynamic fuzzy neural network

1 引言

模型辨识是负荷建模的核心和难点, 也是影响模型准确性和可靠性的关键因素. 随着我国电力网络规模不断扩大、复杂程度越来越高, 电力负荷在电力系统长期动态过程中不可避免地承受较大的电压及频率扰动, 负荷的非线性、变结构特征表现愈加明显, 用单一结构负荷模型已无法准确描述其特性. 因此, 设计有效的辨识算法对负荷建模具有重要的意义.

近年来, 智能控制理论及模糊神经网络得到了广泛应用, 国内外学者提出了许多负荷建模的方法^[1-6]. 文献 [1] 采用模型地貌结构响应优化方法来辨识离线负荷模型; [2] 利用小波神经网络进行负荷辨识; [3] 基

于广域测量系统构建复杂电力系统模型; [4] 将支持向量机 (SVM) 应用于电力系统动态负荷建模中; [5] 利用广义回归神经网络建立电力系统综合负荷模型; [6] 提出了一种基于径向基循环神经网络的电力系统综合负荷建模方法. 纵观已有文献, 负荷模型大都采用 BP 或改进的 BP 算法训练网络, 集中于对负荷模型静态参数的辨识, 而关于动态负荷模型结构和参数的同时辨识则很少涉及.

本文提出一种动态模糊粒神经网络 (DFGNN) 算法, 对电力负荷进行建模. 在粒计算商空间理论基础上, 将输入变量逐次进行划分, 通过等价类数据逼近建立负荷模型. 由于该方法是基于椭圆基函数, 用模

收稿日期: 2010-01-07; 修回日期: 2010-04-12.

基金项目: 国家自然科学基金项目(60743009, 60873035).

作者简介: 陶永芹(1960—), 女, 讲师, 博士生, 从事智能计算、粒计算等研究; 崔杜武(1945—), 男, 教授, 博士生导师, 从事进化计算、数据挖掘等研究.

模糊 ζ -完备性作为在线参数分配机制,避免了初始化选择的随机性.评价体系不仅包含了模糊规则,而且引入了输入变量的重要性,使每条规则的输入变量宽度可以根据其对系统性能贡献的大小实施在线自适应调整.该网络结构小、学习速度快,适于对负荷结构和参数进行动态辨识.仿真实验表明,DFGNN算法具有学习效率高、应用领域广、可行性好等特点.对于缩短辨识时间、提高模型拟合精度均具有显著的作用.

2 粒计算商空间理论

2.1 粒计算商空间基本概念

2.1.1 模糊商空间^[7]

定义1 设给定一个论域 U 和 U 上的一个模糊等价关系 R . R 可等价地用三元组 $(U/R, f(U/R), T(U/R))$ 上的一个归一化等腰距离 $d(A, B)$ 来表示.对于 $\forall A, B \in U/R$,定义 $\mu_A(B) = 1 - d(A, B)$.于是,每个 μ 定义了 U/R 上的一个模糊集.这些模糊集构成的空间对应于模糊等价关系 R 的模糊商空间 $(U/R, f(U/R), T(U/R))$.

2.1.2 分层递阶法

分层递阶法是解决复杂问题的一种方法.该方法先将问题分解或简化,忽略其中细节;然后从较抽象的概念层次着手,一层层地深入到细节,直至问题获得解决.

2.2 商空间关系推理原理

商空间理论在研究不同粒度之间的关系、合成、综合、分解和推理时,用到了如下两个重要的基本原理:

1) 保假原理^[8].若一个命题在粗粒度空间中为假,则该命题在比它细的空间中一定也无解.

2) 保真原理^[8].若一个命题在两个较粗粒度商空间中为真,则在其合成的商空间中所对应的问题也是真的.

依据上述原理,当将复杂问题化成较粗粒度空间进行求解时,若得出该问题无解,则由“保假原理”可以判断原问题无解;若有解,则根据“保真原理”,其合成空间也有解.由于在粗粒度空间计算量少,可以用较少的计算量得出所要结果,从而将“相乘”问题降为“相加”问题,降低了求解的复杂度.

3 动态模糊神经网络辨识的概念及特点

3.1 模糊神经网络

模糊理论在知识和规则获取中可发挥重要作用,人类语言和思维均具有模糊性、广泛性、完美性和高效性等特征.但是,模糊系统缺乏自学习和自适应

能力.而神经网络能够模拟人脑内部结构,在模拟推理、自动学习等方面接近于人脑的自组织和并行处理能力.但神经网络不适于表达基于规则的知识.因此若将两者有机地结合,吸取两者的长处,则可组织比单独神经网络系统或单独模糊系统性能更好的系统.在现有的模糊神经网络中,神经网络的作用只是对模糊系统参数进行学习和优化,并对可能发生的变化在参数上作自适应调整.这就需要预先划分好输入空间,即预先确定神经网络的结构,然后确定模糊规则数.一个模糊神经网络结构的大小是由模糊规则数决定的.从神经网络的角度看,评价一个神经网络好坏的核心指标是其泛化能力.而泛化能力的大小虽然与初值选取和学习策略密切相关,但最重要的因素仍是结构的选择.

3.2 动态模糊神经网络的特点

所谓“动态”是指模糊神经网络的网络结构不是预先设定,而是动态变化的.即在学习开始之前没有一条模糊规则,其模糊规则是在学习过程中逐渐形成的.较之常见的模糊神经网络,DFGNN具有以下特点:

1) 在线学习训练.即采用连续学习方法,每次只用一个观测数据来学习,学习前无须准备好所有的训练数据.

2) 参数估计与结构辨识同时进行.既提高了学习速度,又省去了使用者预先确定结构的麻烦.

3) 学习速度快而有效.由于应用了分层递阶法策略,可大大提高学习效率.

4) 因为在训练过程中直接用商空间来划分整个输入空间,故所得模糊规则数并不随输入变量的增加而指数增长.

3.3 动态模糊神经网络的结构

DFGNN算法的结构如图1所示.




图1 DFGNN的结构

第1层为输入层.每个节点分别表示一个输入的商空间变量,即 x_1, x_2, \dots, x_r .

第2层为商空间变量的隶属函数层.每个节点分别代表一个隶属函数,该隶属函数为如下高斯函

数:

$$\mu_{ij}(x_i) = \exp\left(-\frac{(x_i - c_{ij})^2}{\sigma_j^2}\right),$$

$$i = 1, 2, \dots, r, j = 1, 2, \dots, u. \quad (1)$$

其中: μ_{ij} 是 x_i 的第 j 个隶属函数; c_{ij} 是 x_i 的第 j 个高斯隶属函数的中心; σ_j 是 x_i 的第 j 个高斯隶属函数的宽度; r 是输入变量数; u 是隶属函数的数量, 也为系统总的规则数。

第3层为 T -范数层. 每个节点分别代表一个可能的模糊规则中的 If-部分. 因此, 该层节点数反映了模糊规则数. 第 j 个规则 R_j 的输出为

$$\phi_j = \exp\left(\sum_{i=1}^r (x_i - c_{ij})^2 / \sigma_j^2\right) = \exp\left(-\frac{\|X - C_j\|^2}{\sigma_j^2}\right), j = 1, 2, \dots, u. \quad (2)$$

其中: $X = (x_1, x_2, \dots, x_r) \in \mathbf{R}^r$, $C_j = (C_{1j}, \dots, C_{rj}) \in \mathbf{R}^r$ 是第 j 个径向基单元的中心。

第4层为归一化层. 称这些节点为 N 节点. 显然, N 节点数与模糊规则节点数相等. 第 j 个节点 N_j 的输出为

$$\psi_j = \phi_j / \sum_{k=1}^u \phi_k, j = 1, 2, \dots, u. \quad (3)$$

第5层为输出层. 该层中的每个节点分别表示一个输出变量, 该输出是所有输入信号的叠加, 即

$$y(X) = \sum_{k=1}^u w_k \cdot \psi_k. \quad (4)$$

其中: y 是变量的输出, w_k 是第 k 条规则的结果参数或连接权。

4 动态模糊神经网络的负荷辨识

利用 DFGNN 算法进行负荷辨识, 首先采用粒商空间理论将所有负荷扰动数据构成论域 U , 如季节、时间等负荷数据. 这些负荷组成的关系图是论域的结构 T . 按不同负荷约束条件将论域划分成不同粒度商空间 ($[X], [f], [T]$), 便可得到论域的一个商空间 ($U/R, f^{(U/R)}, T^{(U/R)}$). 如果再考虑其他约束条件, 则可得到论域的不同商空间. 再利用模糊等价关系与分层递阶结构, 便形成了神经网络的结构. 不同的粒度本质上就是选择合理的约束条件和结构 T , 将复杂问题简单化, 从而为负荷模型的建立提供了有效的方法. 由于现场负荷数据的扰动 (电压激励) 不同, 有必要对每组负荷扰动数据分别建模, 然后考察各负荷模型对相同电压激励的响应. 如果两个负荷模型对相同电压激励的响应是一致的, 则表明这两个模型是等价的. 对于不同的样本, 可得到不同粒度的商空间 ($[X], [f], [T]$), 经过神经网络辨识, 便可得到不同的负荷模型. 如果再添加一部分样本进行辨识, 则可得

到另一模型. 循环执行, 直至最后. 将得到的各模型进行合成, 从而得到系统的综合负荷模型。

4.1 模糊规则产生准则

定义2 (模糊规则的 ζ^- 完备性^[9]) 对于某个变化范围内的输入, 如果至少存在一条模糊规则, 使得匹配对 (即触发权) 的值不小于 ζ^- , 则认为这样的模糊系统具备 ζ^- 完备性。

从模糊规则观点看, 一条模糊规则是输入-输出空间中的一个局部表达. 如果一个新的样本满足 ζ^- 完备性, 则它不会产生新的规则, 通过更新现有规则参数便能包容该样本。

定义3 (辨识误差的判据^[9]) 对于第 i 个观测数据 (\mathbf{X}_i, t_i) (其中: \mathbf{X}_i 是输入向量, t_i 是期望的输出), y 是 DFGNN 的输出。

辨识误差为 $\|e_k\| = \|t_k - y_k\|$. 如果 $\|e_k\| > k_e$, 则应考虑增加一条新的模糊规则. k_e 是预先定义的一个阈值, 其值为

$$k_e = \begin{cases} e_{\max}, & 1 < k < n/3; \\ \max[e_{\max}\beta_k, e_{\min}], & (n/3) \leq k \leq (2n/3); \\ e_{\min}, & (2n/3) < k \leq n. \end{cases} \quad (5)$$

其中: e_{\min} 是模糊神经网络期望的输出精度; e_{\max} 是选择的最大误差; n 是样本数; k 是学习的次数; $\beta \in (0, 1)$ 称为收敛常数, 可以推导出 $\beta = (e_{\min}/e_{\max})^{3/n}$.

定义4 (可容性边界的判据^[9]) 对于第 i 个观测数据 (\mathbf{X}_i, t_i), 计算输入值 \mathbf{X}_i 与现有神经网络单元的中心 C_j 之间的距离 $d_i(j)$, 即

$$d_i(j) = \|\mathbf{X}_i - C_j\|, j = 1, 2, \dots, u, \quad (6)$$

其中 u 是现有模糊规则或神经网络单元的数量. 需要找出

$$d_{\min} = \operatorname{argmin}(d_i(j)). \quad (7)$$

如果 $d_{\min} > k_d$, 则应考虑增加一条新的模糊规则; 否则, 观测数据 \mathbf{X}_i 可由现有的神经网络表示. k_d 是可容纳边界的有效半径, 即

$$k_d = \begin{cases} d_{\max} = (\ln(1/\varepsilon_{\min}))^{1/2}, & 1 < k < (n/3); \\ \max[d_{\max}\gamma_k, d_{\min}], & (n/3) \leq k \leq (2n/3); \\ d_{\min} = (\ln(1/\varepsilon_{\max}))^{1/2}, & (2n/3) < k \leq n. \end{cases} \quad (8)$$

$$\gamma = \left(\frac{d_{\min}}{d_{\max}}\right)^{\frac{3}{n}} = \left(\frac{\ln(1/\varepsilon_{\max})}{\ln(1/\varepsilon_{\min})}\right)^{\frac{3}{n}}. \quad (9)$$

其中: d_{\max} 是输入空间的最大长度, d_{\min} 是最小长度, $\gamma (0 < \gamma < 1)$ 是衰减常数. 可见只有当 $\|e_i\| > k_e$, $d_{\min} < k_d$ 时需要增加一条模糊规则. 其中新产生的规则初始参数按如下公式分配:

$$C_i = X_i, \quad (10)$$

$$\sigma_i = kd_{\min}, \quad (11)$$

其中 $k(k > 1)$ 为重叠因子.

定义 5 (灵敏度 B_{ij}) 表示第 j 个规则中第 i 个输入变量的重要性. 即

$$B_{ij} = \rho_{ij} / \sum_{k=2}^{r+1} \rho_j(k),$$

$$i = 1, 2, \dots, r, j = 1, 2, \dots, u,$$

其中 ρ_{ij} 为第 j 个规则中第 i 个输入变量对应的误差减少率.

误差分级学习法. 首先确定产生输出误差大且未被现有模糊规则覆盖的位置, 实现全局学习, 即粗学习. 随着不断学习, 边界逐渐减小. 当 k_e 和 k_d 分别达到 e_{\min} 和 d_{\min} 时, 开始局部学习, 即细学习.

4.2 差分方程负荷模型参数辨识

本文选择串并行线性二阶差分负荷模型, 采用分级递推参数辨识. 其综合模型辨识包括模型结构确定和参数辨识. 设动态差分负荷模型为^[10-11]

$$y(k) = \hat{f}(y_m(k-1), y_m(k-2), \dots, y_m(k-N_y)), \\ u(k), u(k-1), \dots, u(k-M_u), \theta). \quad (12)$$

其中: y_m 为系统输出的观测值, $y(\cdot)$ 为模型输出, \hat{f} 为模型输入输出映射函数, $u(\cdot)$ 为模型输入, N_y 和 M_u 分别为输出、输入变量的延迟阶数, θ 为模型参数.

模型参数辨识可描述为

$$\min_{\theta} J(\theta) = \sum_{k=L}^N (y_m(k) - y(k))^T (y_m(k) - y(k)). \quad (13)$$

其中: $L = \max(n, m) + 1$, N 为观测数据的个数. 对于给定的 n 组不同扰动幅度、不同扰动形式的测量数据为

$$\begin{aligned} & y_m^{(1)}(k), u^{(1)}(k), 1 \leq k \leq N_1; \\ & y_m^{(2)}(k), u^{(2)}(k), 1 \leq k \leq N_2; \\ & \vdots \\ & y_m^{(n)}(k), u^{(n)}(k), 1 \leq k \leq N_n. \end{aligned}$$

基于递推法的负荷动态特性综合就是寻找 $f(\cdot)$ 的近似结构 $\hat{f}(\cdot)$ 及估计参数 $\hat{\theta}$, 使得模型在 n 组给定初值 $y_m^1(L - N_y), y_m^1(L - N_y + 1), \dots, y_m^1(L - 1)$ ($i = 1, 2, \dots, n$) 以及 $u^{(i)}(k)$ ($i = 1, 2, \dots, n, k = -M_u, \dots, N_i$) 的情况下, 其响应与实测响应能较好地拟合.

4.3 负荷模型参数辨识流程

模糊神经网络通过误差反向传播进行参数修正, 其辨识过程为用网络的输出 (模型响应) $\hat{f}(t)$ 对训练样本序列各时间点对应的实际系统响应 $y(t)$ ($t =$

$1, \dots, N$) 的逐一学习拟合. 因此, 对于每一时间点 t , 都有一个不同的参数矩阵 $\theta(t)$ 与之对应. 当对整个训练样本辨识过程结束后, 网络最终所得参数即为对应于最后时间点的 $\theta(N)$. 其辨识算法过程如图 2 所示.

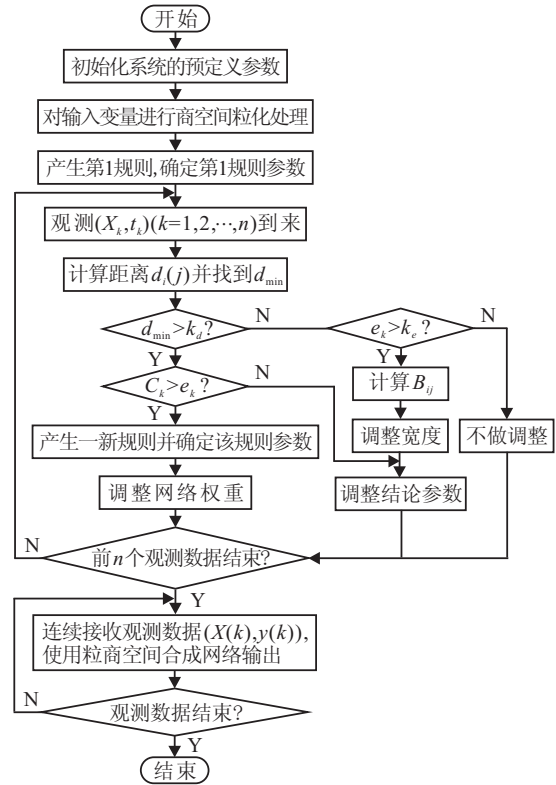


图 2 DFGNN 算法负荷模型参数辨识流程

4.4 负荷模型参数辨识的实现步骤

DFGNN 算法的具体实现步骤如下:

- 1) 初始化系统预定义参数, 对输入的负荷进行商空间粒化处理, 求出粒负荷等价类.
- 2) 当第 1 个等价类输入时, 生成第 1 个规则并确定第 1 规则的参数.
- 3) 接收观测数据 $(x(k), y(k))$, 根据式 (6) 和 (7) 计算 $d(j)$ 和 d_{\min} .
- 4) 如果 $d_{\min} > k_d$, 则转步 5); 否则, 转步 7).
- 5) 如果 $c_k > e_k$, 则转步 6); 否则, 调整结论参数, 转步 7).
- 6) 增加一条新的规则, 确定最新产生的规则参数, 调整权重, 转步 8).
- 7) 如果 $e_k > k_e$, 则计算灵敏度 B_{ij} , 调整宽度及参数.
- 8) 判断前 n 个观测数据结束否. 如果结束, 则转步 9); 否则, 转步 3).
- 9) 连续接受观测数据 $(x(k), y(k))$, 进行粒商空间合成, 求出综合负荷模型.
- 10) 判断总的观测数据是否结束. 如果没结束, 则转步 9); 否则, 转步 11).

11) 结束.

5 仿真实验及分析

为了验证DFGNN算法的辨识性能, 对多输入单输出系统在Matlab7中进行仿真实验. 设待辨识系统差分方程的负荷模型为

$$Y(k) = a_{y1}Y(k-1) + a_{y2}Y(k-2) + b_{u0}U(k) + b_{u1}U(k-1) + b_{u2}U(k-2).$$

其中: $y(k)$ 为有功 $P(k)/P_0$ 或无功 $Q(k)/Q_0$, P_0 和 Q_0 为扰动前稳定的有功功率和无功功率; $U(k)$ 为电压 $U(k)/U_0$, U_0 为扰动前电压; $a_{y1}, a_{y2}, b_{u0}, b_{u1}, b_{u2}$ 为模型参数. 取输入为 $u(k) = \sin(2\pi k/25)$, 选择如下参数: $\varepsilon_{\min} = 0.5, \varepsilon_{\max} = 0.8, e_{\min} = 0.03, e_{\max} = 0.5, k_m = 0.5, k_s = 0.9, k_{\text{err}} = 0.003$. 仿真结果得到的参数为: $a_{y1} = 0.4323, a_{y2} = 0.9978, b_{u0} = -0.4422, b_{u1} = -0.4422, b_{u2} = 0.140$, 产生的规则、解平方根误差、实际输出误差和辨识结果分别如图3~图5所示.




图3 产生的规则及解平方根误差




图4 实际输出误差




图5 目标数据和辨识数据的比较

从图3的解平方根误差和图4可以看到, 实时估计时, 估计误差在前80个数据时较为明显. 这是因为对于前80个输入数据而言, 算法处于训练阶段, 其网络结构还在动态变化且权值正被调整, 所以算法的性

能在该阶段并不令人满意. 在80个数据以后, 算法的结构和参数逐渐稳定下来. 由图4可见, 稳定后的误差已被限制在0.1以下, 共产生了5条模糊规则. 为了进一步检验DFGNN算法的性能, 表1列出了DFGNN算法与D-FNN^[12], GD-FNN^[13]和ANFIS^[14]算法的比较结果.

表1 不同算法的结构与性能比较

方法	规则数	参数的数量	训练的均方根误差	测试的均方根误差	训练速度
DFGNN	5	87	0.0219	0.0221	16.20
D-FNN	9	126	0.0532	0.0541	21.43
GD-FNN	6	98	0.0224	0.0226	17.36
ANFIS	9	106	0.0217	0.0229	20.10

由表1可见, DFGNN算法表现出了较高的性能.

6 结论

本文采用动态模糊神经网络进行电力负荷参数辨识, 该方法利用知识粒模糊推理方法对样本集进行了分析和分类处理, 使样本集更加规范. 利用神经网络学习机制补偿了模糊系统的不足, 使其在合理的仿真粒度内快速实现了动态负荷辨识, 从训练样本特性和网络结构两个方面提高了网络模型的泛化能力. 仿真实验与性能比较验证了该方法的可行性与有效性. 由于粒计算还处于发展阶段, 此方法只是一个尝试, 还有待于进一步研究.

参考文献(References)

- [1] Lukasz J. Off-line identification of dynamic loads[J]. Structural and Multidisciplinary Optimization, 2008, 37(2): 609-623.
- [2] Zapranis A, Alexandridis A. Model identification in wavelet neural networks framework[C]. Int Federation for Information Processing. Hanoi, 2009, 296: 267-276.
- [3] Yang H M, Wen J Y. Power system aggregate load area dynamic modeling by learning based on WAMS[C]. Lecture Notes in Computer Science. Berlin, 2009, 5553: 1179-1188.
- [4] 章健, 王雷涛, 张锋. 基于SVM的电力系统动态负荷建模的研究[J]. 继电器, 2008, 36(7): 38-46. (Zhang J, Wang L T, Zhang F. Study of dynamic load modeling for power systems based on SVM[J]. Relay, 2008, 36(7): 38-46.)
- [5] 余健明, 李萌, 舒菲. GRNN算法在电力系统负荷建模中的应用[J]. 电力系统及其自动化学报, 2009, 21(1): 104-107. (Yu J M, Li M, Shu F. Application of GRNN-algorithm on load modeling of power system[J]. Proc of the CSU-EPSA, 2009, 21(1): 104-107.)