

应用模糊神经网络进行负荷预测的研究¹⁾

张昊

吴捷 郁滨

(广东省科学院自动化工程研制中心 广州 510070) (华南理工大学电力学院自动控制工程系 广州 510641)

摘要 应用模糊神经网络实现的预测系统通过对历史数据的自适应学习获得初始的模糊预测模型,借助等价结构的 ANN 基于实时数据的梯度信息对系统参数进行 BP 训练,具有较强的适应性和自学习能力。以电力短期负荷预测(STLF)为应用背景,进行了系统化的实验研究,结果表明这一智能化的预测系统的性能是令人满意的。

关键词 模糊神经网络,短期负荷预测,经济预测,函数逼近。

APPLYING FUZZY NEURAL NETWORK TO LOAD FORECAST

ZHANG Hao

(Automation Engineering R&M Center, Guangdong Academy of Sciences, Guangzhou 510070)

WU Jie YU Bin

(Electric Power College, Dept. of Control Engineering, South China University of Technology, Guangzhou 510641)

Abstract The accomplished forecasting system can achieve an initial fuzzy forecasting model by means of adaptive learning from historical data, and can train its parameters by BP algorithm of ANN of equivalent structure based on gradient information of real time data. Thus, the system possesses distinguished adaptive feature and self-learning capability. Taking electric power load forecasting as application background, we put forward a series of experiment research. Experiment results demonstrate satisfactory performances of the intelligent forecasting system.

Key words Fuzzy neural networks, short-term load forecasting, economic forecasting, function approximation.

1 引言

电力系统对未来负荷进行预测的必要性在于:系统内的可用发电量在正常运行情况下,应在任何时刻都满足系统负荷的要求。目前,电能尚不能大量储存,电力生产与消费又

1)广东省攻关项目和广东省科学院院长青年基金项目。

收稿日期 1997-07-18 收到修改稿日期 1998-03-14

是同时进行的,为保证电力系统的可靠性和安全性,电力规划和运行调度^[1]都必需以负荷预测为依据.负荷预测是否具有实用价值,关键在于是否具有较高的预测精度.本文研究的是国内研究较少而现场又最为需要的日负荷曲线的预测问题,即每天预测未来24个整点时刻的负荷值.

人工神经网络(ANN)和模糊理论是两类非常有效的预测技术^[2-6].ANN模拟人的直观性思维,特色在于信息的分布式存储和并行协同处理,具有集体运算和自适应学习的能力.模糊理论将操作人员的经验表达为规则的形式,并转换成可以在计算机上运行的算法.与ANN类似,模糊逻辑(FL)可以用有限的规则近似任意的函数关系,并对系统扰动不敏感^[4].对于不易建立精确数学模型的、具有多种不确定性和非线性的系统,应用FL往往可以处理常规方法难以解决的问题.实验对比说明^[5],应用FL和ANN的负荷预测精度明显优于常规的回归分析.国际上在ANN负荷预测方面的研究已趋于成熟^[2,3],模糊负荷预测的理论体系有待逐步完善^[6].同时获得了ANN和FL长处的FNN可以进一步改善负荷预测的品质.当前,如何用FNN来提高整个系统的学习能力和表达能力是学术界一个倍受瞩目的课题.至今国内还没有将FNN用于负荷预测的研究,在国外也才刚刚开始^[7,8].

本文以实际应用为目标,研究一种学习结合型的FNN,预测系统由模糊逻辑系统(FLS)表示,FLS的隶属函数的参数通过ANN的BP学习算法来调整.这里的ANN不再是一个黑箱,而是由等价结构的FLS转化来的,其节点和参数都具有一定的意义,即对应FLS的隶属函数和推理过程.这类FNN便于今后将较为成熟的FL或专家系统预测模型转化为FNN,利用ANN的计算能力和对环境变化的自适应学习能力获得更精确的预测.

2 学习结合型的FNN

2.1 初始模糊预测模型的建立

本文研究的FNN预测系统主体是FLS,系统设计和实现的第一步是建立初始的FLS.这里,FLS的模糊规则不是来自于专家经验,而是学习样本数据后自动产生的.

首先将系统输入输出空间按等分原则进行分割.由样本数据中求出对应于每一输入 x_i 的 x_i^{\min} 和 x_i^{\max} ,将 $[x_i^{\min}, x_i^{\max}]$ 分成 M_i 个等份,每个等分点对应一个模糊子集 A_{ij} , $j=0, 1, \dots, M_j$. A_{ij} 的隶属函数采用等宽度的三角形(或钟型),三角形的纵向顶点对应相应的等分点 \bar{x}_i ,在该点 $\mu_{A_{ij}}(\bar{x}_i)=1$,三角形的两个横向顶点位于相邻两个等分点 \bar{x}_{i-1} 和 \bar{x}_{i+1} ,即各相邻三角形在隶属函数为0.5处相交.输出的隶属函数为棒形,即将样本数据中的输出区间 $[y_{\min}, y_{\max}]$ 分为 M 等分,各等分点对应模糊子集 B_j , $j=0, 1, \dots, M$.

在线运行的规则自适应学习算法如下:

步骤1.对于MISO系统,依次由样本集中取一样本 $(x_{1k}, x_{2k}, \dots, x_{nk}, y_k)$.

步骤2.用该样本产生一条规则.

对于每个输入变量 x_i ,取 $\mu_{A_{ij}}(x_{ik})$ 最大值对应的模糊子集作为规则条件部中 x_i 的语言变量,即 $X_{ik}=\max_j \mu_{A_{ij}}(x_{ik})$ 对应的 A_{ij} , $j=0, 1, \dots, M_i$.取 $i=1, 2, \dots, n_i$,则可以形成完整的规则条件部(对应 n_i 个输入变量).对于规则的结论部,取 $Y_k=\text{距离 } y_k \text{ 最近的 } B_j, j=0,$

1, \dots, M.

步骤3. 为规则赋予一个置信度.

由步骤2获得了一条模糊规则 k , 其形式如下:

$$R^{(k)}: \text{如果 } x_1 \text{ 为 } X_{1k}, x_2 \text{ 为 } X_{2k}, \dots, x_n \text{ 为 } X_{nk}, \text{ 则 } y = Y_k. \quad (1)$$

因这一规则是由实际样本数据中获得的, 定义其置信度为

$$w_k = \mu_{X_{1k}}(x_{1k}) \times \mu_{X_{2k}}(x_{2k}) \times \dots \times \mu_{X_{nk}}(x_{nk}). \quad (2)$$

步骤4. 规则集一致性检验.

将该条规则与规则集中已有的每条规则相比较, 如果有一条规则与其条件部 $X_{ik}, i=1, 2, \dots, n_i$, 完全相同、结论部有异, 则保留置信度 (w_k) 大的规则, 删除另一个; 否则, 将该规则 k 加入规则集.

步骤5. 重复上述各步, 直到取完所有的样本数据, 就形成一个规则集.

获得规则集之后, 具有这一初始预测模型的模糊系统已经具有自适应的预测能力了, 系统的预测输出为^[10]

$$\hat{y} = \frac{\sum_{j=1}^R \mu_j Y_j}{\sum_{j=1}^R \mu_j}, \quad (3)$$

其中 μ_j 是输入对应第 j 条规则的适用度 (也可称置信度或真值), 即

$$\mu_j = \mu_{X_{1j}}(x_1) \times \mu_{X_{2j}}(x_2) \times \dots \times \mu_{X_{nj}}(x_n). \quad (4)$$

这一算法可以很方便地推广到多输入多输出的情况, 即在结论部由 y_i 得出相应的 Y_{ik} 即可.

2.2 将模糊预测系统表示为等价结构的 ANN

为了叙述的严谨, 先定义下面的变量符号: y_k, \hat{y}_k 分别为第 k 次迭代时的样本输出值 (期望值) 和预测输出值; x_i^k 为各输入变量, 本文中 $i=1, 2, 3$; \bar{x}_i^r 为第 r 条规则中对应第 i 个输入的模糊子集 X_i^r 的隶属函数的中心点, $X_i^r \in \{A_{i1}, A_{i2}, \dots, A_{iM_i}\}$, 其中 A_{ij} 为对应于 x_i 的各模糊子集, $M_1=M_2=3, M_3=7$; σ_i^r 为与 \bar{x}_i^r 相应的钟形隶属函数的宽度; \bar{y}_r 为第 r 条规则的结论部, 与上面的 Y_i 意义相同, 这里使用这一符号表示每条规则都有不相同的结论部, 即初始建模时以样本实际输出值为规则结论; μ_r 为第 r 条规则在输入为 x_i^k 时的适用度, 有

$$\mu_r = \prod_{i=1}^n \mu_{X_i^r}(x_i^k) = \prod_{i=1}^n \exp\left[-\left(\frac{x_i^k - \bar{x}_i^r}{\sigma_i^r}\right)^2\right]. \quad (5)$$

上述 FLS 采用与三角形等价的钟形 (高斯型) 隶属函数时的一般性表达为^[4]

$$\hat{y} = f(x) = \frac{\sum_{r=1}^R \bar{y}_r \mu_r}{\sum_{r=1}^R \mu_r} = \frac{\sum_{r=1}^R \bar{y}_r \left\{ \prod_{i=1}^n \exp\left[-\left(\frac{x_i - \bar{x}_i^r}{\sigma_i^r}\right)^2\right] \right\}}{\sum_{r=1}^R \left\{ \prod_{i=1}^n \exp\left[-\left(\frac{x_i - \bar{x}_i^r}{\sigma_i^r}\right)^2\right] \right\}}. \quad (6)$$

这样的模糊系统, 可以用图1所示的前向网络来表示. 其中, (A)层为输入层, (E)层为输出层. (B)层称为模糊化层, 各神经元执行对应 $x_{ik} (i=1, \dots, n; k=1, \dots, n_i)$ 的隶属函数, 输出的是 $\mu_{x_{ik}}(x_i)$. (C)层称为模糊推理层, 各神经元相当于乘法器, 输出的是各条规则的适用

度 μ_j . (D)层可称为模糊判决层或非模糊化层,与(E)层一起执行(3),而(C)层与(D)层中 \sum_1 神经元(加法器)连接中的权值就是各规则的结论部 y_j ,其余权值均为1.

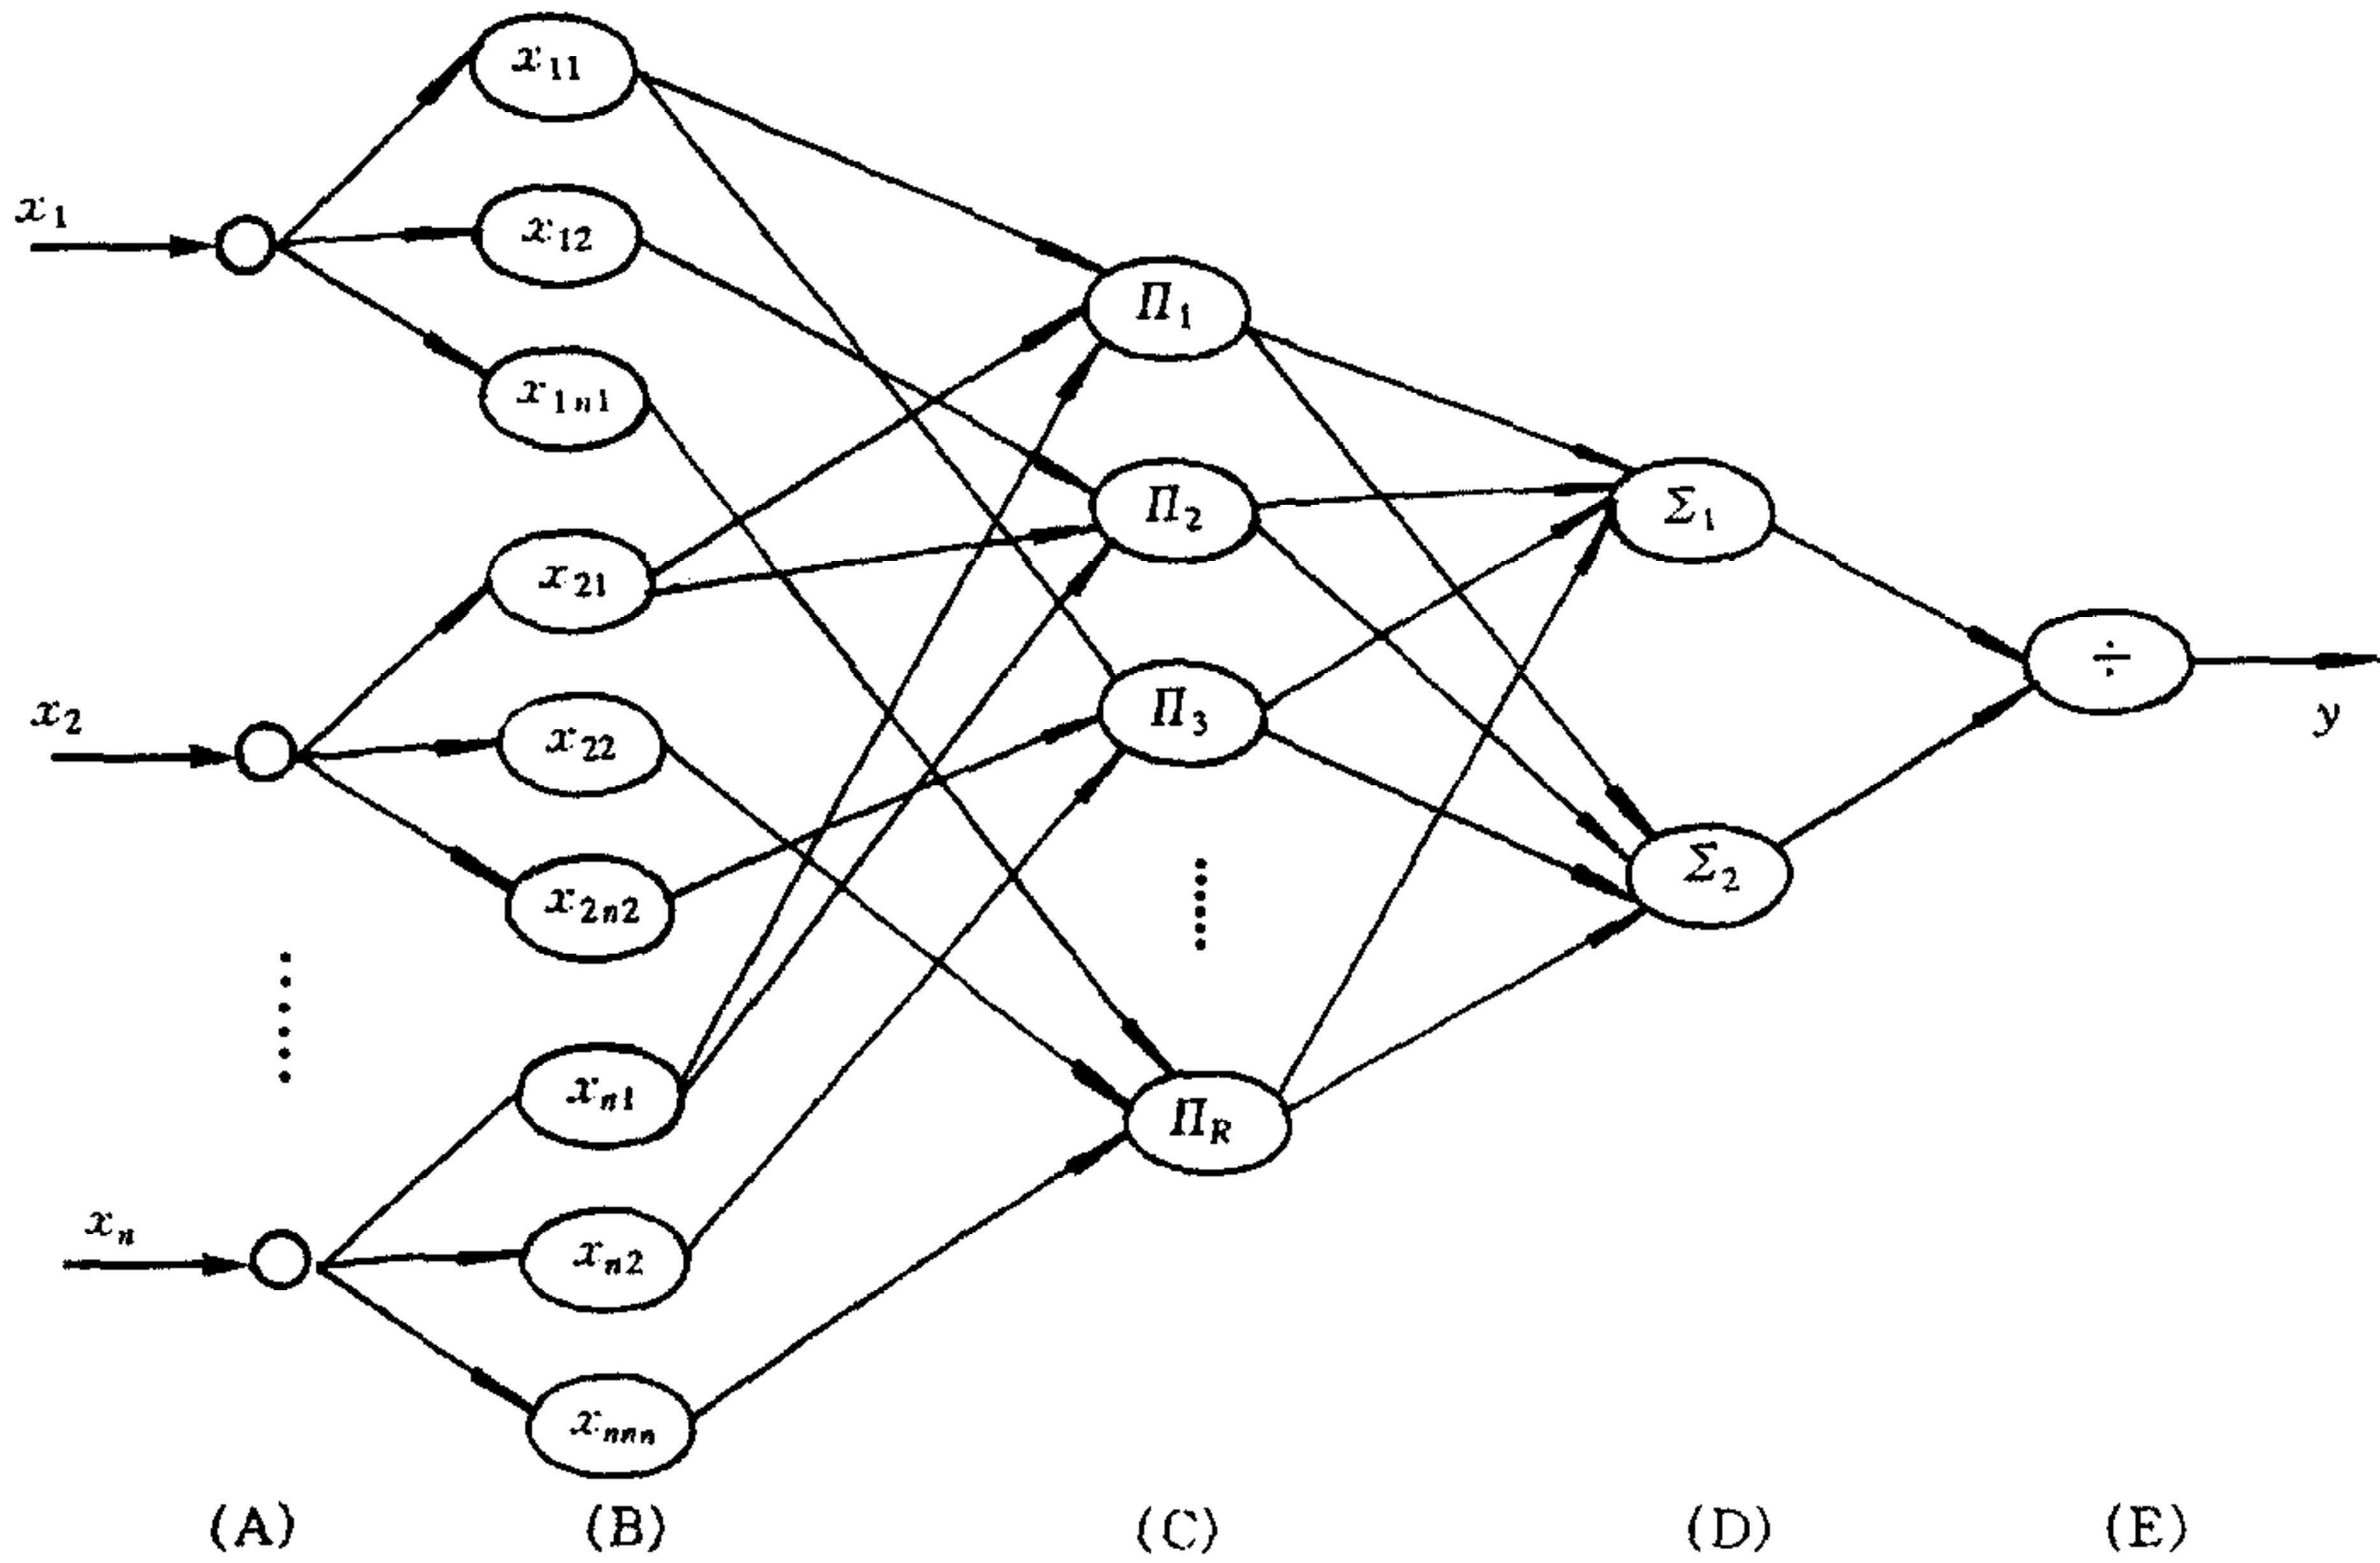


图1 与模糊逻辑系统等价的神经网络结构

将初始模糊预测模型表示为这一前向网络后,可以对其使用基于梯度下降的 BP 算法进行学习训练,优化调整参数后的模糊预测系统将具有更强的自适应特征和学习能力.如果反向传播学习只进行到(C)层,就是本文实验中只对规则结论部 \bar{y}_r 进行调整的情况,进行到(B)层时是对所有参数都调整.

2.3 用 ANN 学习预测系统的参数

对于初始的模糊预测模型,可调的参数包括输出模糊子集(一般采用棒形隶属函数)的中心 \bar{y}_r 、输入模糊子集隶属函数的中心和宽度.这里,用 θ 代表其中任意参数,用 BP 算法学习的通式为

$$\theta(k + 1) = \theta(k) - \alpha \frac{\partial e(k)}{\partial \theta} \Big|_{\theta = \theta(k)}, \tag{7}$$

其中, k 为迭代学习序号, α 为控制学习速度的参数,误差变量定义为

$$e(k) = \frac{1}{2} (y_k - \hat{y}_k)^2. \tag{8}$$

由(7)和(8)可得到

$$\theta(k + 1) = \theta(k) + \alpha (y_k - \hat{y}_k) \cdot \frac{\partial \hat{y}_k}{\partial \theta} \Big|_{\theta = \theta_k}, \tag{9}$$

因此,只要求出 \hat{y}_k 对各参数的偏微分,就可以用式(9)对其进行训练了.

BP 算法进行到(C)层,调整模糊规则的结论部,由式(3)和(4)可以得出

$$\frac{\partial \hat{y}_k}{\partial Y_i} = \frac{\mu_i}{\sum_{i=1}^R \mu_i}, \quad i = 1, 2, \dots, R. \tag{10}$$

BP 算法进行到(B)层,调整模糊系统对应于输入变量各隶属函数的参数. 设第 k 次学习的样本为 (x_k, y_k) , 应用函数求偏导的方法, 由式(6)得到所需的偏导数后代入式(9)可得到对 \bar{x}_i^r 和 σ_i^r 的 BP 优化调整迭代公式

$$\bar{x}_i^r(k+1) = \bar{x}_i^r(k) - \alpha \frac{\hat{y}_k - y_k}{\sum_{r=1}^R \mu_r} (\bar{y}_r - \hat{y}_k) \cdot \mu_r \cdot \frac{2[x_i^k - \bar{x}_i^r(k)]}{[\sigma_i^r(k)]^2}, \quad (11)$$

$$\sigma_i^r(k+1) = \sigma_i^r(k) - \alpha \frac{\hat{y}_k - y_k}{\sum_{r=1}^R \mu_r} (\bar{y}_r - \hat{y}_k) \cdot \mu_r \cdot \frac{2[x_i^k - \bar{x}_i^r(k)]^2}{[\sigma_i^r(k)]^3}. \quad (12)$$

上式中, $i=1, 2, 3$; $r=1, 2, \dots, R$; $k=0, 1, 2, \dots$.

3 FNN 短期负荷预测系统

3.1 预测系统的结构

在解决负荷预测的问题时, 只有当那些对负荷影响较大的因素都包含在输入之内时, 才有可能作出准确的负荷预测. 本系统采用了如下表述的三个输入变量: 1) 当前(T 时刻)最新获得的整点负荷值 $x_1 = L(T)$; 2) T 时刻负荷与该时刻历史数据平均值之差 $x_2 = L(T) - \bar{L}(T)$; 3) 历史数据中($T+1$)时刻与 T 时刻平均值之差 $x_3 = \bar{L}(T+1) - \bar{L}(T)$. 其中, $\bar{L} = \frac{1}{3}[L(T-7 \times 24) + L(T-14 \times 24) + L(T-21 \times 24)]$ 代表过去三周同类型日(指星期几) T 时刻负荷的平均值. 如果过去三周同类型日中某天正好是节日, 则取再前一周同类型日的数据; 如果当前 T 处于节日中, 则取前三个节日的数据.

上述三个变量的选取意义如下: 因为下一时刻未知负荷 $L(T+1)$ 的预测必然是在当前负荷的基础上发展, 选取 x_1 为输入是容易理解的, 该输入包含了负荷的增长信息, 是预测的基准; 选择 x_2 作为输入的主要目的是将显著影响负荷又难于获取的当前天气情况包含在输入之中, 即以负荷的变动隐含天气的变动信息; x_3 的选取提供了历史数据中 T 到 $(T+1)$ 时刻的负荷变化趋势信息, 这对于提前一步的负荷预测(模拟负荷变化的相似性)是重要的, 同时它也为模糊系统的训练提供了基础, 即这一输入中包含负荷的动态信息. STLF 中一个棘手的问题就是对节假日的负荷应以特殊的模式进行预测, 本系统通过输入变量选取及其在历史数据中的取值解决这一问题, 使简化的预测系统具有更强的适应性和实用性.

为不使系统复杂化, STLF 的输出选择提前一步的预测. 当得出下一时刻的 $y(T+1)$ 预测后, 以其为当前已知数据继续预测 $y(T+2)$. 依此类推, 得到完整的未来24小时的预测输出.

3.2 FNN 负荷预测的实现

本文所述的 FNN 预测系统的结构如图2所示.

实时预测中, 各输入变量 x_i 经过隶属函数转化为模糊量 \tilde{x}_i . 隶属函数的设计会影响预测的精度和系统鲁棒性. 总的原则是^[9]: 对于那些与输出的因果关系主要是线性的输入, 隶属函数个数应选取得少些; 非线性度越大, 则应多设一些隶属函数. 因为 x_1 和 x_2 主要是线性变动因素, 对它们选取三个隶属函数, 而 x_3 的非线性特征更明显, 定义七个隶属

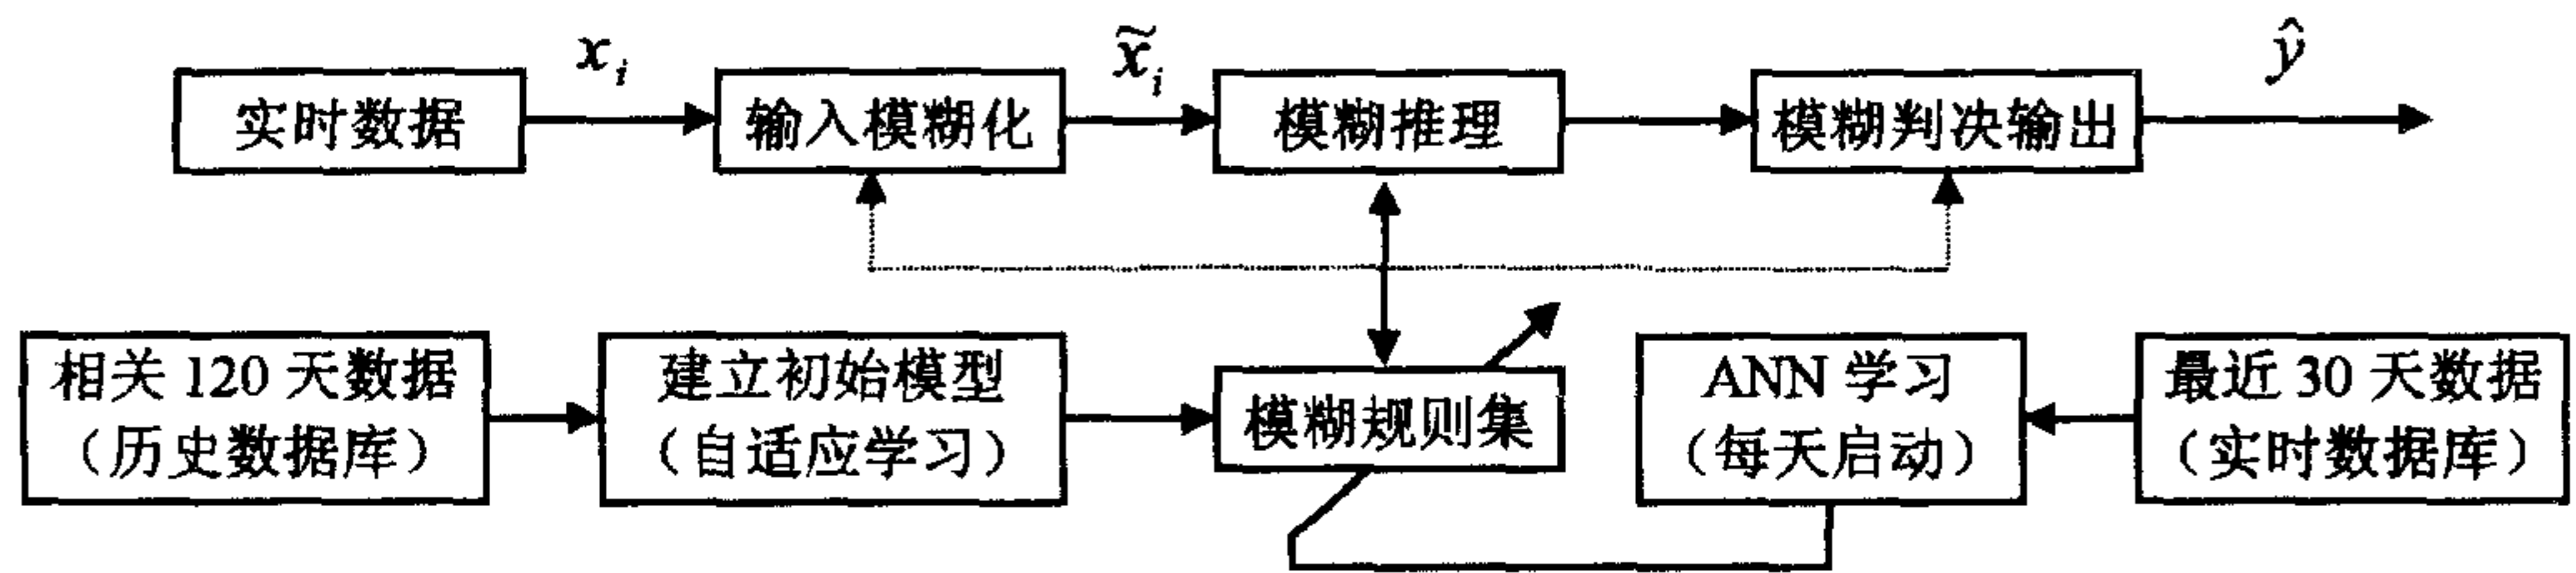


图2 FNN 预测系统结构框图

函数. 则本系统可能的规则数为 $R=3 \times 3 \times 7=63$.

规则 r. “IF x_1 is A_{1i}^r , AND x_2 is A_{2j}^r , AND x_3 is A_{3k}^r , THEN y_f is \bar{y}_r .”

这里, $i, j=1, 2, 3; k=1, \dots, 7; r=1, \dots, R$. 这 R 条规则的表达式为: “如果 T 时刻负荷为零/中/大, 且 T 时刻与历史数据相比的变化为正/零/负, 且历史数据 T 到 $(T+1)$ 时刻的变化趋势是正大/正中/正小/零/负小/负中/负大, 则 $(T+1)$ 时刻的负荷预测是 \bar{y}_r .” 规则基础上的模糊推理如式(3)和(4).

4 FNN 负荷预测系统的实验研究

本文用广东省某市的实测数据完成的 STLF 实验结果如表1所示, 其中:

0. 将初始模糊预测模型用于负荷预测, 未经 FNN 优化的系统预测结果并不很令人满意.

1. 加入对规则结论部 \bar{y}_r 的调整, 每组学习样本使用1次, 学习控制因子 $\alpha=0.28$.

2. 不仅调整 \bar{y}_r , 而且调整规则条件部(对应各输入)的各模糊子集的隶属函数中心点和宽度, 每组样本最多学习40次, 学习控制因子分别为 $\alpha=0.8, \alpha_c=0.1, \alpha_w=0.1$.

3. 由于发现对隶属函数中心点的调整有可能混乱, 实验3及以后的程序加入了限制, 即当本次对隶属函数中心的调整违背了相邻模糊子集的大小设置时, 则取消本次调整. 实验证明这一限制不仅合理而且有效. 由于增加学习迭代次数并不能改进性能, 每组学习样本最多学习20次, 且找到了最优的学习参数 $\alpha=0.68, \alpha_c=0.01, \alpha_w=0.01$.

4. 将上一程序改为每组学习样本只学习1次. $\alpha=0.68, \alpha_c=0.08, \alpha_w=0.05$. 实验表明, 只调整规则结论部时, 一轮迭代就可以寻到最优, 这从一个侧面说明初始建模获得的规则结论都是较为合理的. 当加入了对 \bar{x}_i 和 σ_i 的调整后, 应该多迭代一些次数, 但却要以运行时间为代价. 我们曾做过20000次的迭代, 结果并无改善. 因此, 最后定型的预测系统采用迭代一次的设计, 这加强了系统的实用性, 并利于向超短期预测推广.

5. 每天进行学习迭代前, 先将规则结论部恢复为初始模型的数值, 以改进系统性能. 但只有恢复规则结论部是有效的, 其它参数的恢复反而使预测结果恶化. 这说明建模中以实测值作为规则结论是较好的选择, 恢复这些参数有意义.

6. 第一个输入 x_1 设置为两个模糊子集(原为三个). 由于调整隶属函数中心和宽度效果不明显, 进一步的改进应该改变隶属函数的数量. 实验6的恶化的预测结果说明, 隶属函数数量的改变是有意义的. 用试探法寻找最优的结果显然是无法实现的, 我们考虑引入遗传算法来解决这一寻优问题, 并已开始实验研究.

实验2—6的结果表明:FNN 预测系统参数的 BP 调整是非常有效的,预测精度明显优于初始模型.由于规则结论部直接决定预测输出值,且采用的是将输出空间“无级细分”的设计,调整这些参数的效果很明显;由于输入隶属函数参数调整中的非线性关系较复杂,用基于梯度下降的 BP 算法寻优,效果不明显.

表1 FNN 短期负荷预测系统的实验结果(表中数据为平均百分相对误差 MP AE——%)

序号	3月19日 星期日	3月20日 星期一	3月21日 星期二	3月22日 星期三	3月23日 星期四	3月24日 星期五	3月25日 星期六	3月26日 星期日	月均 MPAE
0	6.440	8.718	7.393	7.487	7.574	8.593	6.961	7.116	6.9045
1	3.940	5.961	4.091	4.404	4.290	5.386	5.053	5.194	3.5754
2	2.291	5.165	4.431	2.948	2.959	4.545	4.834	3.239	3.4553
3	2.339	4.669	3.481	3.602	3.042	4.759	3.999	3.485	3.3149
4	3.028	4.989	3.572	3.226	3.522	4.508	4.549	4.202	3.3771
5	3.028	5.277	3.482	3.549	3.766	4.703	4.324	4.240	3.3052
6	2.917	5.357	4.162	4.237	3.253	5.787	4.587	4.789	3.3622

为了更具有说服力,表1选用三月最差的一周预测结果(因三月下旬正处于季节转换中,负荷变化规律也在随之改变).对比分析表中各列可以发现,本方法对各类型日的预测效果良好,特别是传统方法难以处理的休息日的预测结果不亚于工作日.图3和4是周末的详细实验结果.




图3 3月18日(星期六)的预测结果




图4 3月19日(星期日)的预测结果

5 结束语

凡是一个既包括 ANN 的结构或思想(算法)又使用了 FL 的系统,都可以称为 FNN.

在 FNN 预测系统中,模糊系统和神经网络可以有各种相互融合的形态.文献[7]采用串联型的 FNN 结构,其基本思想是利用专家经验形成模糊规则,而将模糊输入、输出之间的不明确关系留给 ANN 去掌握.文献[8]采用并联型的 FNN 结构,由 ANN 产生预测输出的主要部分,同时用专家经验对其进行修正,最终获得了比传统的指数平滑法精确很多的预测效果.与这些已有的 FNN-STLF 系统不同,本文研究的是结构较为复杂的学习型结合 FNN 预测系统.这一系统既可以总结专家经验形成模糊规则,也可以从数据信息中自动生成模糊规则.该系统巧妙地将 ANN 的自适应学习能力与 FLS 获取定量与定性知识的能力结合在一起,并通过建立合理的初始模型避免 ANN 局部收敛的缺陷,是一种优化的智能化预测方法.实验结果表明,本系统的短期负荷预测精度具有较强的鲁棒性,可以满足实用化的要求.

参 考 文 献

- 1 张昊,吴捷.通用的集成电力调度自动化系统.中国电力,1997,30(3):16—19
- 2 Ho K L. Short term load forecasting using a multilayer neural network with an adaptive learning algorithm. *IEEE Trans. on Power Systems*, 1992, 7(1):141—148
- 3 Mohammed O. Practical experiences with an adaptive neural network short-term load forecasting system. *IEEE Trans. on Power Systems*, 1995, 10(1):254—265
- 4 Wang L X. Adaptive Fuzzy System and Control——Design and Stability Analysis. New York:PTR Prentice Hall, 1994
- 5 Liu K, Subbarayan S, Shoults R R, et al. Comparison of very short-term load forecasting techniques. *IEEE Trans. on Power Systems*, 1996, 11(2):877—882
- 6 Mori H, Kobayashi H. Optimal fuzzy inference for short-term load forecasting. *IEEE Trans. on Power Systems*, 1996, 11(1):390—396
- 7 Srinivasan D, Chang C S, Liew A C. Demand forecasting using fuzzy neural computation, with special emphasis on weekend and public holiday forecasting. *IEEE Trans. on Power Systems*, 1995, 10(4):1897—1903
- 8 Kim K H, Park J K, Hwang K J, et al. Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems. *IEEE Trans. on Power Systems*, 1995, 10(3):1534—1539
- 9 Mori H, Kobayashi H. Optimal fuzzy inference for short-term load forecasting. *IEEE Trans. on Power Systems*, 1996, 11(1):390—396
- 10 赵振宇,徐用懋.模糊理论和神经网络的基础与应用.清华大学出版社,广西科学技术出版社.1996

张 昊 男,1969年生,1991年毕业于国防科技大学自动控制专业;1994年获华南理工大学生物电子学硕士学位;1997年华南理工大学自动控制理论及应用专业博士毕业.主要研究方向为智能控制理论与应用、电力系统自动化以及工业自动化工程等.

吴 捷 男,1937年生.1961年毕业于哈尔滨工业大学电力系统自动控制专业.现为华南理工大学教授、博士生导师,电力学院院长.长期从事自适应控制、计算机控制系统及电力系统自动化等方面的研究.