

模块化模糊神经网络的数值预报 产品释用预报研究*

金 龙

(广西气象减灾研究所, 南宁, 530022)

林 熙

(海南省气候中心, 海口, 570203)

金 健

(广西气象减灾研究所, 南宁, 530022)

李 菁

(广西气象台, 南宁, 530022)

摘 要

综合应用预报量自身时间序列的拓展, 数值预报产品和模块化模糊神经网络方法, 进行了一种新的数值预报产品释用预报研究。将这种新方法 with 常规的数值预报产品完全预报(PP)方法进行了对比试验。结果表明, 这种模块化模糊神经网络数值预报产品释用预报方法比 PP 预报方法的预报精度显著提高。并且, 通过对预报模型“过拟合”现象的研究发现, 这种模块化模糊神经网络的数值预报产品释用预报模型具有很好的泛化性能。

关键词: 模块化网络, 模糊系统, 数值预报产品, 泛化性能。

1 引 言

随着国内外中期数值预报模式的不断改进和提高, 中期数值预报模式预报产品的解释预报应用已成为中期天气预报的重要方法。国家气象中心的新一代数值预报系统(T213), 也已投入业务应用, 从而可以为中期天气预报提供内容更为丰富的数值预报产品资料。然而目前中期数值预报产品的解释应用方法主要是依据数值预报产品, 很少考虑其它因素。并且在方法上主要是运用一些常规的统计学和天气学等预报技术, 并依据预报建模方法的出发点不同, 主要分为 MOS 方法和完全预报方法(PP法)^[1,2]。近年来, 在非线性人工智能研究领域中, 由人工神经网络方法与模糊数学方法相结合形成的模糊神经网络方法, 由于综合了神经网络与模糊数学方法的一些良好性能, 因而在其他很多学科领域取得了一些很好的应用研究成果^[3~5]。文中主要尝试以模块化模糊神经网络方法结合预报量序列延拓, 进行数值预报产品的解释预报应用研究。这种模块化模糊神经网络方法预报建模的重要特点是预

报模型用模糊系统表示, 而规则提取和隶属度函数是由神经网络方法通过学习训练产生的。

2 预报建模的基本原理分析

一般最常用的数值预报产品完全预报(PP)方法, 是通过将预报量与数值预报分析场资料的相关计算, 找出与预报量相关高的物理量场相关区(格点)作为因子, 采用逐步回归等预报方法建立预报方程。并假设预报量与未来时刻预报场也存在这样的相关关系, 因而进一步将不同时刻的对应预报场资料替代分析场资料做出未来时刻的预报。该方法最早是由 Klein^[6]提出的, 其一般的数学表达式为:

$$y = f(\hat{x}_t) \quad (1)$$

其中 $\hat{x}_t$ 为数值预报产品的预报场资料。

由式(1)可以看到, 该预报方法仅仅考虑了数值预报产品的预报场资料。然而对于一般的温度预报问题, 特别是对于日平均气温或日最高、最低气温的预报问题, 在气象学科中, 常常采用时间序列分析预报方法, 其中最常用的是自回归预报模型^[7,8], 该方法的预报方程形式为:

* 初稿时间: 2002 年 9 月 2 日; 修改稿时间: 2002 年 10 月 21 日。
资助课题: 国家自然科学基金项目(40075021)。

$$y_t = \beta_1 y_{t-1} + \beta_2 y_{t-2} \cdots \beta_p y_{t-p} + \epsilon_t \quad (2)$$

其中 y_t 为预报量时间序列, β_i 为模型系数, ϵ_t 为白噪声。如果式(2)的预报对象为日平均气温,则方程(2)的预报建模依据是认为某天的平均气温变化与 $t-1, t-2 \cdots t-p$ 时刻的前期日平均气温有关,即可以广义认为,日平均气温一维实测时间序列的未来值与过去一些值存在着一个递归关系:

$$y = F(y_{t-1}, y_{t-2} \cdots y_{t-p}) \quad (3)$$

显然式(3)的预报是建立在某天的日平均气温与前期日平均气温的统计相关基础上的统计预报方法。在实际预报工作中,确实大量的日平均气温时间序列存在式(3)这样的递归关系。这种预报建模方法属于纯统计预报方法。而式(1)的预报方法是建立在数值预报产品基础上的统计-动力预报方法。然而在实际预报工作中,是否可以考虑在日平均气温的预报方法中将式(1)和(3)两种预报方法进行融合,即在一般的统计-动力预报方法中,同时考虑预报量时间序列的递归关系,设计一种新的预报模型:

$$y = \Phi(\hat{x}_t, y_{t-1}, y_{t-2} \cdots y_{t-p}) \quad (4)$$

其中 $\hat{x}_t$ 为预报时刻的数值预报模式预报场输出产品, $y_{t-1}, y_{t-2} \cdots y_{t-p}$ 则为预报量自身时间序列的前期观测值。显然,只要数值预报产品的预报场资料及预报量自身时间序列的前期值与预报量存在很好的相关关系,则利用式(4)来建立一种新的预报模型是有依据的。基于这样的分析,本文尝试在原来数值预报产品的完全预报(PP)方法基础上,进一步结合自回归模型预报方法进行一种新的数值预报产品释用预报方法研究。并且在预报建模的方法上,采用由模糊理论与人工神经网络方法相结合形成的模块化模糊神经网络方法^[9~11]。

3 模块化模糊神经网络结构

模块化模糊神经网络是由模糊规则网络和规则适应度网络组成,其中模糊规则网络是用来表示模糊规则结论部函数。在模糊规则网络中,第 j ($1 \leq j \leq c$) 条规则对应的模糊规则网络输出,表示规则 j ($1 \leq j \leq c$) 对输入样本的运算结果。令权值 $b_j = [b_{0j}, b_{1j} \cdots b_{pj}]^T$, 它可以用最小均方(LMS)算法调整。对于输入样本维数为 p 的外部输入 $X = [1, x_1, x_2 \cdots x_p]$, 则第 j 个模糊规则网络对输入 X 的输出为:

$$y_j = X^T \cdot b_j \quad (5)$$

因而,第 j 条规则对应的模糊规则网络对第 k 个样本的输出为:

$$y_j(k) = X_k^T \cdot b_j \quad (6)$$

其中 $X_k = \{x_{k1}, x_{k2} \cdots x_{kp}\}$ 。在模块化模糊神经网络中的规则适应度网络是一个多层网络,该网络是用于计算给出每条规则对输入的每个样本 X_k 的适应度 $g_1(k), g_2(k), \cdots g_c(k), k=1, 2 \cdots n$, 其中 p 为输入样本维数, n 为输入样本数, c 为规则条数。对于第 j 条规则输入空间的中心向量 $z_j = [z_{1j}, z_{2j} \cdots z_{pj}]^T$, 则可以根据 n 个输入样本由下式计算确定:

$$z_j = \left\{ \frac{\sum_{k=1}^n [\mu_j(k)]^\lambda x(k)}{\sum_{k=1}^n [\mu_j(k)]^\lambda} \right\} \quad (7)$$

其中 $j = 1, 2 \cdots c$

隶属矩阵 $u = |\mu_j(k)|_{c \times n}$ 满足:

$$\sum_{j=1}^c \mu_j(k) = 1, \text{ 且 } \mu_j(k) \in [0, 1] \quad (8)$$

其中 $k = 1, 2 \cdots n$

它表示第 k 个样本对第 j 条规则的适应度,可由模糊 c 均值聚类算法(FCM)调整生成。 $\lambda \in [1, \infty)$ 为模糊加权指数,可根据实际问题确定。在模糊规则网络的学习过程中,当隶属矩阵调整好后,即可用式(7)确定中心向量。

在规则网络结构中: $0 \leq g_j(k) \leq 1$, 且 $\sum_{j=1}^c g_j(k) = 1$ 。因此,模糊系统第 k 个样本输出为:

$$Y(k) = \sum_{j=1}^c g_j(k) \cdot y_j(k) \quad (9)$$

模块化模糊神经网络的结构如图1所示,由该网络结构可以看出,模块化网络是由规则适应度网络和模糊规则网络两部分组成,其中适应度网络是采用模糊 C 均值(FCM)聚类方法,将输入样本 X 划分成 C 个子域作模块化处理,每个适应度子网络 g_j 是表示第 j 条规则下,输入样本 X_k 的适应度,即 X_k 隶属于规则 j 的程度。在整个输出系统式(9)中,




图1 模块化模糊神经网络结构

第 j 条规则的适应度网络:

$$g_j(k) = \mu_j(k) / \sum_{i=1}^c \mu_i(k) \quad (10)$$

而式(9)中的规则网络即式(6)是在适应度网络的基础上,采用的一种单层神经网络,其结构简单,网络需调节权值数较少,学习复杂度较低。在规则适应度网络部分,是基于 FCM 的网络结构,具有较好的网络表达能力。

4 模块化模糊神经网络学习算法

模块化模糊神经网络系统的学习训练是一种混合学习算法,其中对于模糊规则网络是采用有教师的最小二乘学习算法,而规则适应度网络的训练是采用无教师的模糊 c 均值聚类算法。对于规则适应度网络的学习,首先定义目标函数 J :

$$J(u, z) = \sum_{k=1}^n \sum_{j=1}^c (\mu_j(k))^\lambda \cdot (d_{jk})^2 \quad (11)$$

$\lambda \in [1, \infty)$ 为模糊加权指数; $z_j = [z_{1j}, z_{2j}, \dots, z_{pj}]^T$, $z_j \in R^p$ 是第 j 条规则输入空间的中心向量可由式(7)计算得到,其中隶属矩阵 $u = [\mu_j(k)]_{c \times n}$ 满足条件式(8)。

$$\begin{aligned} (d_{jk})^2 &= \|x(k) - z_j\|^2 \\ &= \sum_{i=1}^p [x_i(k) - z_{ij}]^2 \end{aligned} \quad (12)$$

$\|\cdot\|$ 为 Euclidean 范式。

因此,模糊 c 均值的聚类算法可归结为:

① 确定规则条数 c , 加权指数 λ , 中止误差 ϵ_μ , 最大迭代次数 H 。

② 初始化隶属度矩阵 $u^{(0)}$ (给定一组随机数)。

③ 取 $I = 0$ 。

④ 根据 $u^{(IT)}$ 计算 z_j 。

⑤ 计算隶属度:

$$\mu_j(k) = \left(\frac{d_{1k}}{d_{jk}} \right)^{\frac{2}{\lambda-1}} / \left(\sum_{i=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{\frac{2}{\lambda-1}} \right) \quad (13)$$

⑥ 若 $\|u^{(I)} - u^{(I+1)}\| < \epsilon_\mu$ 或 $I > H$, 停止; 否则 $I = I + 1$, 并返回④。

通过上述 FCM 算法离线对规则适应度网络进行训练,从而确定每条规则输入空间的中心向量。当模糊系统训练结束时,便可进一步计算得到预测样本对每条规则的隶属度。对于模糊规则网络的学习是在上述规则适应度网络训练结果的基础上,采用最小二乘算法进行的有导师训练过程。因此可以定义误差函数:

$$E = \frac{1}{2} [Y(k) - Y^*(k)]^2 \quad (14)$$

式中, $Y(k)$ 为模糊系统输出值; $Y^*(k)$ 为期望值, 规则网络中权值 b_j 的训练过程归结为:

① 确定迭代误差 ϵ 、最大迭代次数 H 、学习率 α 。

② 取 $I = 0$ 。

③ 按下述方法更新 $b_j^{(IT)}$, (对 $k = 1 \sim n$)

$$\begin{aligned} Y(k) &= \sum_{j=1}^c g_j(k) \cdot y_j(k) \\ &= \sum_{j=1}^c g_j(k) \cdot (X_k^T \cdot b_j) \end{aligned} \quad (15)$$

$$\begin{aligned} b_j(IT+1) &= b_j(IT) - \alpha [y(k) - \\ & y^*(k)] \left[\frac{X_k}{X_k \cdot X_k^T} \right] \cdot g_j(k) \end{aligned} \quad (16)$$

④ 若 $\|b_j(k) - b_j(k+1)\| < \epsilon$ 或 $I > H$, 停止; 否则 $I = I + 1$, 并返回③。

由式(15)便可得到模块化模糊神经网络预测模型的预测值。

5 两种预报方法的对比分析

首先以广西北部、中部和南部 3 个代表站, 桂林、柳州和南宁 2001 年春季(2~4 月)共 89 d 的日平均气温序列作为预报研究对象。根据常规的完全预报(PP)方法, 计算出欧洲中心中期数值预报模式 850 hPa 温度分析场资料与上述 3 站日平均温度序列的相关格点, 将达到相关显著性水平的格点作为基本预报因子, 采用回归方法建立 3 个站的基本预报方程:

$$\begin{aligned} y &= 7.327 + 0.267x_1 + 0.134x_2 + \\ & 0.086x_3 + 0.164x_4 \end{aligned} \quad (17)$$

$$\begin{aligned} y &= 5.675 + 0.784x_1 + 0.386x_2 + \\ & 0.326x_3 - 0.267x_4 \end{aligned} \quad (18)$$

$$\begin{aligned} y &= 3.635 + 0.541x_1 + 0.199x_2 + \\ & 0.729x_3 - 0.514x_4 - 0.182x_5 \end{aligned} \quad (19)$$

为了统一的对比检验分析, 3 个站的预报方程样本均取第 3 至 74 天的前 72 个样本, 而最后 15 d 作为预报方程的独立样本用于预报检验。方程(17), (18)和(19)的复相关系数分别为 0.8646, 0.8753, 0.8707 (n 均为 72)。以方程(17), (18)和(19)为基本方程, 将后 15 d 需要预报的 48 h 的预报场资料代替原方程中的分析场资料即可得到常规 PP 方法的预报结果(表略)。计算结果表明 PP 方法对 3 个站 15 d 的逐日平均气温的预报平均绝对

误差分别为:2.31℃(桂林)、3.23℃(柳州)和 2.07℃(南宁)。

然而,由第 2 节的分析知道,要利用式(4)建立带有预报量后延序列的模糊神经网络统计动力预报模型,则预报量自身时间序列必须具有很好的时滞相关。为此,进一步分别计算了桂林、柳州和南宁 3 个站 2001 年 2~4 月,89 d 日平均气温序列的前 74 个样本与各自序列的 2 个后延序列的相关。结果发现,3 个站日平均气温序列与其 2 个后延序列的相关系数均超过 0.001 相关显著水平(见表 1)。

表 1 预报量与延拓序列的相关

站 名	后 延	相关系数
桂 林	$\tau = t - 1$	0.85
	$\tau = t - 2$	0.70
柳 州	$\tau = t - 1$	0.85
	$\tau = t - 2$	0.65
南 宁	$\tau = t - 1$	0.84
	$\tau = t - 2$	0.61

由表 1 可以看到,这 3 个站的日平均气温序列与其自身序列的后延相关具有很好的相关关系,这显然为利用式(4)建立新的统计动力数值预报产品解释应用预报模型提供了依据。因此,本文在常规的数值预报产品完全预报(PP)方法基础上,进一步加入该预报量自身预报序列的 2 个拓展序列,采用模糊神经网络方法来建立预报模型。并考虑到实际的预报时效,在实际预报建模过程中,将各个站的第一个延拓序列均用本站该日的最低气温值代替。据此可以得到最终的,同时包括了常规 PP 方法所考虑的数值预报产品资料及预报量自身延拓序列的模糊神经网络学习矩阵。再利用第 4 节的模块化模糊神经网络预报建模方法,分别建立 3 个站的预报模型。图 2 分别给出了桂林、柳州和南宁 3 个站模糊神经网络预报模型对输入矩阵学习样本的训练误差




图 2 误差函数随训练次数的变化
(实线为桂林,虚线为南宁,点划线为柳州)

收敛情况。由图可以看出,由于模糊神经网络的规则网络是采用的单层网络,其结构不含隐层,不需要进行隐节点的调试。因此当规则数取 4,学习率取 0.005,加权指数取 3,对训练样本作 1300 次训练后,其误差函数趋于平稳,便可利用各模型参数得出带有预报量自身延拓序列的数值预报产品模糊神经网络预报模型。

图 3 给出了桂林、柳州、南宁 3 个站 72 d 日平均气温实测值和预报模型对历史样本的拟合值。由图 3 可以看出,模糊神经网络预报模型对历史样本的拟合精度相当高,3 个站实测值与拟合值的相关系数分别为 0.9337(桂林)、0.9464(柳州)、0.9459(南宁),而实测值与拟合值的平均值绝对误差分别为:1.15,1.56 和 1.63℃。这种新的数值预报产品释用预报方法对 3 个站 15 d 日平均气温独立样预报平均绝对误差分别为 1.39℃(桂林)、1.57℃(柳州)和 1.64℃(南宁),其中误差下降最大的柳州站,15 d 48 h 预报的平均预报误差比前面的常规 PP 方法预报误差下降了近一半,3 个站平均预报绝对误差下降了 1℃。原来 3 个站 PP 方法 15 d 的平均预报相对误差为 13.9%,而带有时间序列延拓序列的模糊神经网络方法 3 个站的平均预报相对误差 7.7%,预报精度提高十分显著。显然,这种预报能力的提高不仅与采用的预报建模方法有关,同时由于本文提出的这种改进方法比传统的 PP 预报方法更多地考虑了预报量时间序列的延拓序列也有相当作用,这可以从更多方面反映对预报量未变化的影响因素,具有合理的分析依据。

另外,由于模糊神经网络方法是由神经网络方法与模糊数学方法相结合形成的一种新方法,该方法应用于数值预报产品的释用预报是一种新的预报尝试。而普通神经网络方法应用于预报建模时,常会出现“过拟合”现象^[12],即网络预报模型对训练样本的拟合精度很高,而对检测样本的推广能力较差,这是普通神经网络方法应用于实际天气预报建模中尚未很好解决的最重要问题。为此有必要进一步分析模糊神经网络方法应用于数值预报产品释用预报建模时是否出现“过拟合”现象。由图 2 已经看到,桂林、柳州、南宁 3 个站的模糊神经网络预测模型误差收敛函数在训练次数 1300 次区域内十分平稳,而本文对 3 个站的预测模型均是取训练次数达到 1300 次的各模型参数进行历史样本的拟合值计算和独立样本的预报计算。为了分析考察这种预报模

型参数的稳定性和预报模型是否可能出现“过拟合”现象,进一步根据训练误差函数在平稳区间的 1000 次训练到 2500 次训练模型参数,分别进行 3 个站各自 15 d 的独立样本和 72 个建模样本预报检验分析(见表 2)。结果发现随着训练次数的改变(从 1000

次到 2500 次),3 个站的模糊神经网络预报模型对历史样本的拟合精度虽然有所提高,但是,独立样本的预报平均绝对误差和平均相对误差变化并不明显,没有出现“过拟合”现象,具有很好的泛化性能。显然这对于实际业务预报的应用推广具有重要意义。




图 3 模糊神经网络预报模型的历史样本拟合结果

(实线为实测值,点线为拟合值;a. 桂林, b. 柳州, c. 南宁)

表 2 模糊神经网络预报模型不同训练次数的预报检验分析

训练次数	站点	历史样本拟合		独立样本检验	
		平均绝对误差(°C)	平均相对误差(%)	平均绝对误差(°C)	平均相对误差(%)
1000	桂林	1.18	9.71	1.39	7.75
	柳州	1.24	8.16	1.61	8.05
	南宁	1.14	7.11	1.72	7.67
1300	桂林	1.18	9.73	1.39	7.75
	柳州	1.23	8.08	1.57	7.91
	南宁	1.14	7.11	1.64	7.27
1500	桂林	1.17	9.57	1.34	7.57
	柳州	1.22	8.05	1.61	8.21
	南宁	1.09	6.81	1.65	7.32
1800	桂林	1.16	9.43	1.42	7.93
	柳州	1.22	8.04	1.57	7.88
	南宁	1.09	6.80	1.60	7.12
2000	桂林	1.15	9.41	1.40	7.69
	柳州	1.21	8.01	1.53	7.78
	南宁	1.09	6.79	1.60	7.09
2500	桂林	1.13	9.39	1.41	8.02
	柳州	1.19	7.89	1.62	8.16
	南宁	1.08	6.76	1.60	7.18

6 结 语

数值预报产品的解释应用预报方法是业务预报工作的重要手段和方法,特别是省以下广大气象台站的业务工作。并且可以预期,随着数值预报模式的不断改进和提高,数值预报产品的解释预报会越来越多地被应用于业务预报。然而要进一步改进和提高数值预报产品的释用预报水平,除了依靠数值预报模式的预报水平提高以外,本文的研究结果表明,采用一些新的非线性人工智能方法,并结合考虑一些数值预报产品资料以外的相关因素,可能对改进现有数值预报产品释用预报方法的预报精度具有实用意义。另外,本文对模块化模糊神经网络方法在建模预报中的相关性能分析表明,由模糊规则网

络和规则适应度网络组成的这种模糊神经网络不仅具有模糊数学方法的信息处理和神经网络方法的非线性映射能力等良好性能,更为重要的是与一般的多层人工神经网络方法相比,由于前者的规则网络部分是采用的单层网络,中间不含隐层,不需要调试隐层的节点数。而到目前为止,对于多层神经网络的适宜隐节点确定方法,在理论上还没有很好的解决。同时从本文的分析结果也看到,本文建立的3个站的模块化模糊神经网络的日平均气温预报模型,均没有出现一般多层神经网络方法容易出现的“过拟合”现象。模型参数十分稳定,具有很好的泛化能力,这为进一步开展模糊神经网络方法的天气预报建模研究展示了很好的应用前景。

参考文献

- 1 茅卫平,宋火,钟建平等.航空中期天气预报业务系统.解放军理工大学学报,2000,1(2):83~89
- 2 周家斌,黄嘉佑.近年来中国统计气象学的新进展.气象学报.1997,55(3):297~304
- 3 王伟,吴耿锋,黄冰树等.基于模糊神经网络和符号的地震预报专家系统 NGESP.中国地震,1996,12(4):339~346
- 4 傅继阳,谢壮宁,倪振华.大跨屋盖结构风压分布特性的模糊神经网络预测.建筑结构学报,2000,23(1):62~67
- 5 刘普寅,张汉江,吴孟远.模糊神经网络理论研究综述.模糊系统与数学,1998,12(1):77~87
- 6 Klein W H. Space and time variations in specifying monthly mean surface temperature from the 700mb height field. Mon Wea Rev,1985,113(3):277~290
- 7 金龙,袁成松,秦伟良等.基于预报误差最小的自回归模型定阶方法研究.气象科学.1997,17(1):36~41
- 8 Barbara G B. Time series models to simulate and forecast wind speed and wind power. Journal of Climate and Applied Meteorology,1984,23:1184~1195
- 9 Zhao Xiang, Xiao deyun. Fault diagnosis of nonlinear systems based on modular fuzzy neural network. 控制理论与应用,2001,18(3):395~400
- 10 王士同.神经模糊系统及其应用.北京:北京航空航天大学出版社,1998.210~245
- 11 乔志骏,刘其真,易维列等.一个基于模糊神经网络的数据逼近的泛化建模方法.模式识别与人工智能,2001,14(2):253~256
- 12 Wang Yingchun, Wu Hengxin, Geng Changfu. Study and application of a class of neural networks model with better generalizati ability. Proceedings of the 4th World Congress on Intelligent Control and Automation, Shanghai, China,2002,2016~2020

STUDY ON INTERPRETATION PREDICTION OF NUMERICAL WEATHER PREDICTION PRODUCTS BASED ON MODULAR FUZZY NEURAL NETWORK

Jin Long

(*Guangxi Research Institute of Meteorological Science, Nanning 530022*)

Lin Xi

(*Hainan Climate Center, Haikou 570203*)

Jin Jian

(*Guangxi Research Institute of Meteorological Science, Nanning 530022*)

Li Qing

(*Guangxi Meteorological Observatory, Nanning 530022*)

Abstract

At present, statistical prediction techniques remain dominant in the interpretation of numerical weather prediction products, such as methods of model output statistics (MOS) and perfect prediction (PP). Since the late 1980s the artificial neural network (ANN) characterized by such properties as self-adaptive learning and nonlinear mapping has been investigated extensively and it has become a hot topic in a lot of scientific fields. Research of artificial and wavelet neural networks for practical purpose has been carried out in the meteorological sciences at home and abroad since the 1990s. In recent years the fuzzy neural net from the combination of the ANN and fuzzy reasoning system has rapidly developed and put into use in such fields as artificial intelligence, signal recognition, data integration and management-decision-making because it has the ability of ANN self-adaptive learning and nonlinear mapping and of logic reasoning, language and computation of the fuzzy mathematic system. Up to now, however, little has been reported of applications of the fuzzy neural networks to meteorological prediction and analysis. For this reason, the authors attempt to establish a model for the interpretation of medium-range numerical weather prediction products in the context of modular fuzzy neural network.

The modular-type fuzzy neural network is based on the algorithm of fuzzy C means (FCM) for clustering and consists of a gate net and an expert network, leading to a mixed learning and training algorithm. In this paper, firstly, a dynamic statistical prediction model involving the continuation of time series of a predictand and the medium-range numerical weather prediction products is constructed in terms of modular fuzzy neural network, with the 89 mean daily temperatures over the spring season (February-April) in 2001 as the predictand, using data from three typical stations of Liuzhou, Guilin, Nanning, respectively in the north, the middle, the south of Guangxi. The fitting accuracy for historical samples is much higher from the modular neural network model, the correlation coefficients between measurements and fitting values are 0.9337 (Guilin), 0.9464 (Liuzhou), 0.9459 (Nanning), and yielding mean absolute errors are 1.15°C (Guilin), 1.56°C (Liuzhou), 1.63°C (Nanning), accordingly. In addition, the forecasting results show mean absolute errors is 1.39°C (Guilin), 1.57°C (Liuzhou), 1.64°C (Nanning), respectively, when using 15-day independent samples. But the routine PP model yields mean absolute error of 2.31°C (Guilin), 3.23°C (Liuzhou), 2.07°C (Nanning), for the same three typical stations and data. The computation results further indicate that the fuzzy neural network model gives prediction mean relative error of 7.7%, almost half the figure of 13.9% given by the routine PP model.

The case study shows that the prognostic ability of the developed model is superior to that of a convenient scheme. Our calculation indicates that the modular fuzzy-ANN predictions for independent samples are rather good. Furthermore, the number of tested parameters is much less than that of usual multi-layer networks, leading to higher steadiness of the parameters in operation. As a consequence, the presented model is of greater utility.

Key words: Modular network, Fuzzy systems, Numerical prediction products, Generalization ability.