

# 基于尖峰自组织模糊神经网络的需水量预测

乔俊飞<sup>†</sup>, 张 力, 李文静

(1. 北京工业大学信息学部, 北京 100124; 2. 计算智能与智能系统北京市重点实验室, 北京 100124)

**摘要:** 短期需水量预测是城市给水管网安全稳定运行的前提和保证。针对日需水量预测提出一种基于尖峰机制的自组织模糊神经网络(SSOFNN)模型。针对影响变量复杂多变的特点,采用主成分分析对原始数据进行降维处理,获取线性无关的主成分变量作为预测模型输入数据。SSOFNN模型根据尖峰强度和误差指标在训练过程中对隐含层神经元进行增长修剪,结合改进 Levenberg-Marquardt 算法简化参数更新过程中的计算过程,大大减少了计算量,能够获得紧凑的网络结构,且跟踪精度高,运行时间短,预测效果好。

**关键词:** 模糊神经网络; 自组织; 尖峰机制; 需水量预测; 给水管网

中图分类号: TP183

文献标志码: A

## Prediction of water demand based on spiking self-organizing fuzzy neural network

QIAO Jun-fei<sup>†</sup>, ZHANG Li, LI Wen-jing

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China; 2. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China)

**Abstract:** Short-term prediction of water demand provides basic guarantee for water supply system operation and management. In this study, an effective model for daily water demand forecasting is proposed. Firstly, principle component analysis(PCA) is utilized to simplify the complexity and reduce the correlation between influence variables, and the score values of selected principle components(PCs) turn into the irrelevant input data of fuzzy neural network(FNN), which models the prediction of water demand. Moreover, an improved Levenberg-Marquardt(ILM) algorithm is employed to optimize the parameters of FNN simultaneously, the problems of heavy computing burden and limited memory space can be solved. Most of all, a growing-pruning mechanism based on spiking integrate-and-fire(IF) model is applied to FNN in order to realize structural self-organization. Finally, contrast experiments are implemented to demonstrate that the spiking self-organizing fuzzy neural network(SSOFNN) has better prediction performance and capability to handle practical issues.

**Keywords:** fuzzy neural network; self-organizing; spiking; water demand prediction; water supply network

## 0 引言

随着城市规模的不断扩大和居民生活水平的不断提高,城市需水量持续增长,供水管网稳定安全运行成为保证社会生产和市民生活的必要前提。同时,环境污染严重、能源与水资源日益短缺的现状,在降低能耗、减少漏损方面对城市给水管网的运行管理提出了更高要求。而需水量预测研究是保证供水管网优化运行的重要环节和基本前提<sup>[1]</sup>,其预测精度将直接影响供水优化调度的有效性和可靠性。

近年来,需水量预测的主要方法有回归分析法、时间序列法及人工神经网络等。回归分析法<sup>[2]</sup>要求建立预测量与影响因素之间精确的因果关系模型,但短期需水量具有很强的不确定性,难以进行完善的机理性分析。传统的时间序列法<sup>[3]</sup>易于实现及应用,但其预测结果仅依赖于历史用水量数据,忽略了解释性变量的影响,数据的数量和质量会对预测精度产生较大的影响。人工神经网络具有非线性映射和自适应学习的能力,Jain 等<sup>[4]</sup>利用 6 种人工神经网络、5 种

收稿日期: 2017-07-09; 修回日期: 2017-10-06。

基金项目: 国家自然科学基金项目(61533002, 61603009); 北京市科技专项课题领军人才项目(Z15110000013151010); 北京工业大学日新人才计划项目(2017-RX(1)-04)。

责任编辑: 柴利。

作者简介: 乔俊飞(1968-), 男, 教授, 博士生导师, 从事神经网络智能控制及其应用等研究; 张力(1992-), 女, 硕士生, 从事神经网络建模、需水量预测的研究。

<sup>†</sup>通讯作者。E-mail: zhanglily@emails.bjut.edu.cn

回归分析模型及2种时间序列模型分别对印度理工学院进行短期需水量预测,证明神经网络的预测效果要优于传统的时间序列法和回归分析法。周艳春等<sup>[5]</sup>利用BP神经网络进行短期需水量预测,具有较高的预测精度和可靠性。但是,BP神经网络存在易陷入局部极小点、外插和模型泛化能力弱、收敛速度慢等问题<sup>[6]</sup>。卜义惠等<sup>[7]</sup>结合气温、节假日、阴晴状况等影响因素,利用RBF神经网络建立日用水量动态预测模型,可以克服BP网络的上述缺点,但其预测过程需要更多的隐含层神经元。

针对城市需水量影响因素众多、非线性高、模糊性强、随机性大的特点,本文采用模糊神经网络(FNN)建立预测模型。该方法结合了模糊系统的知识表达能力和神经网络的自学习能力,在解决不确定性和模糊性问题时无需先验知识和假定变量间关系<sup>[8]</sup>。孙月峰等<sup>[6]</sup>利用基于T-S模型的模糊神经网络预测天津市年需水量,在预测精度、训练时间和收敛速度上都优于BP神经网络和非线性回归方法。但是,已有的固定结构模糊神经网络其隐含层节点个数需要通过试凑法确定,在学习过程中无法根据数据规模和变量复杂度动态调整神经元数目。隐含层神经元数目过多,会造成神经网络结构冗余,计算量大,泛化能力差;神经元数目太少,会造成神经网络学习能力不足,预测精度差。因此,在实际应用中需要通过自组织方法实现神经网络的结构调整。张伟等<sup>[9]</sup>分别利用神经元激活强度和规则无用率对模糊神经网络隐含层神经元个数进行增长和修剪。Hsu等<sup>[10]</sup>通过规则可信度实现递归神经网络规则增长,通过各神经元的样本重要性删除冗余单元。但上述方法实现网络结构的增长-修剪分别采用了两种不同的评价体系,可能会因量化标准的不一致在结构调整过程中产生重叠域和空白域。

针对上述问题,本文采用基于大脑皮层信息传递模式和Spiking神经元模型提出的尖峰机制<sup>[11-12]</sup>,实现模糊神经网络增长-修剪阶段的评价标准一致化。Spiking神经元采用基于时间编码的方式,从结构和运行方式上都充分模拟生物神经元间的信息传递方式<sup>[13-14]</sup>。其中,积累触发(Integrate-and-Fire, IF)模型是最常用的Spiking神经元阈值点火模型,在此基础上提出的尖峰机制是以尖峰强度和误差函数作为评价指标<sup>[15]</sup>,实现网络结构的动态调整。

针对城市需水量预测影响因素复杂多变、耦合性强的特点,本文首先采用主成分分析(PCA)对样本数据进行降维处理,提取特征变量作为模糊神经网

络的输入变量;继而采用基于尖峰机制的自组织模糊神经网络建立预测模型,获得紧凑的网络结构;在参数学习过程中采用改进Levenberg-Marquardt(ILM)算法<sup>[16]</sup>,一方面保留了二阶学习算法收敛速度快的优点,另一方面克服了传统Levenberg-Marquardt(LM)算法计算存储负担重、不适用于大样本实例的缺点。此外,通过设计与其他预测方法的对比仿真实验,验证了本文所提出方法预测精度高、网络结构紧凑、收敛速度更快。

## 1 模糊神经网络预测模型

### 1.1 模糊神经网络结构

本文使用一个4层的多输入单输出模糊神经网络建立需水量预测模型,分别为输入层、RBF层、规则化层和输出层,拓扑结构如图1所示。

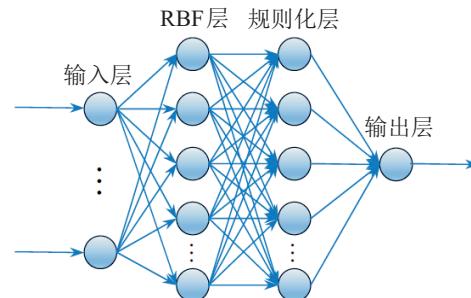


图1 模糊神经网络结构

第1层为输入层。该层有 $k$ 个神经元,主成分分析获得的主成分变量作为每个神经元的输入, $u = [u_1, u_2, \dots, u_k]$ ,第*i*个节点输出为

$$x_i = u_i, i = 1, 2, \dots, k. \quad (1)$$

第2层为RBF层。采用高斯函数计算各神经元的隶属度,该层有 $P$ 个神经元,第*j*个神经元的输出为

$$\varphi_j = \prod_{i=1}^k e^{-\frac{(x_i - c_{ij})^2}{2\sigma_{ij}^2}} = e^{-\sum_{i=1}^k \frac{(x_i - c_{ij})^2}{2\sigma_{ij}^2}}, j = 1, 2, \dots, P, \quad (2)$$

其中 $c_{ij}$ 和 $\sigma_{ij}$ 分别为该层第*j*个神经元中属于第*i*个隶属函数的中心和宽度。

第3层为规则化层。该层和RBF层一样有 $P$ 个神经元,第*l*个神经元的输出为

$$v_l = \frac{\varphi_l}{\sum_{j=1}^P \varphi_j} = \frac{e^{-\sum_{i=1}^k \frac{(x_i - c_{il})^2}{2\sigma_{il}^2}}}{\sum_{j=1}^P e^{-\sum_{i=1}^k \frac{(x_i - c_{ij})^2}{2\sigma_{ij}^2}}}, l = 1, 2, \dots, P. \quad (3)$$

第4层为输出层。输出变量 $y$ 为第2日需水量,计算公式如下所示:

$$y = \sum_{l=1}^P w_l v_l = \frac{\sum_{l=1}^P w_l e^{-\sum_{i=1}^k \frac{(x_i - c_{il})^2}{2\sigma_{il}^2}}}{\sum_{j=1}^P e^{-\sum_{i=1}^k \frac{(x_i - c_{ij})^2}{2\sigma_{ij}^2}}}, \quad (4)$$

其中  $w_l$  是规则化层第  $l$  个神经元与输出层之间的连接权值.

模糊神经网络预测模型的建立主要包括参数学习和结构自组织两方面. 其中参数学习采用 ILM 算法, 同时更新中心、宽度、权值 3 个变量; 结构调整则采用基于尖峰 IF 模型建立的增长-删减机制.

## 1.2 改进 Levenberg-Marquardt 学习算法

传统 LM 算法的更新规则如下所示:

$$\mathbf{w}(t+1) = \mathbf{w}(t) + (\mathbf{J}^T \mathbf{J} + \lambda(t) \mathbf{I})^{-1} \mathbf{J}^T e. \quad (5)$$

其中:  $\mathbf{w}$  为权值向量,  $\lambda$  为学习率,  $\mathbf{I}$  为单位矩阵,  $e$  为误差向量,  $\mathbf{J}$  为  $N \times K$  的雅各比矩阵,  $N$  为样本数量,  $K$  为输出变量个数.

LM 算法作为二阶算法具有收敛速度快的优点, 但在大数据样本的工程应用中, 雅各比矩阵的乘法计算会造成巨大的计算负荷及存储空间. 针对这一问题提出的 ILM 算法<sup>[16-17]</sup>, 通过简化拟海森矩阵和梯度向量的计算过程, 能够有效减少计算量.

首先, 定义变量向量  $\Phi(t)$ , 包含中心向量  $c_j$ 、宽度向量  $\sigma_j$  和权值向量  $\mathbf{w}$ .

$$\begin{aligned} \Phi(t) = & \\ [w_1(t) \cdots w_p(t) \ c_1(t) \cdots c_p(t) \ \sigma_1(t) \cdots \sigma_p(t)]. \end{aligned} \quad (6)$$

基于传统 LM 算法的计算流程, ILM 算法的更新规则为

$$\Phi(t+1) = \Phi(t) - (\mathbf{Q}(t) + \lambda(t) \mathbf{I})^{-1} \Theta(t). \quad (7)$$

其中:  $\mathbf{Q}(t)$  为拟海森矩阵,  $\Theta(t)$  为梯度矩阵, 分别由各自的子矩阵直接相加计算获得.

$$\mathbf{Q}(t) = \sum_{n=1}^N \mathbf{q}_n(t), \quad (8)$$

$$\mathbf{q}_n(t) = \mathbf{j}_n(t)^T \mathbf{j}_n(t); \quad (9)$$

$$\Theta(t) = \sum \phi_n(t), \quad (10)$$

$$\phi_n(t) = \mathbf{j}_n(t)^T e_n(t). \quad (11)$$

其中:  $\mathbf{j}_n(t)$  为第  $n$  ( $n = 1, 2, \dots, N$ ) 个样本的雅各比矩阵的行向量,  $e_n(t)$  为输出神经元的误差值.

$$\begin{aligned} \mathbf{j}_n(t) = & \left[ \frac{\partial e_n(t)}{\partial w_1(t)} \cdots \frac{\partial e_n(t)}{\partial w_P(t)} \frac{\partial e_n(t)}{\partial c_1(t)} \cdots \right. \\ & \left. \left. \frac{\partial e_n(t)}{\partial c_P(t)} \frac{\partial e_n(t)}{\partial \sigma_1(t)} \cdots \frac{\partial e_n(t)}{\partial \sigma_P(t)} \right] \right], \end{aligned} \quad (12)$$

$$e_n(t) = d_n(t) - y_n(t), \quad (13)$$

$y_n(t)$  和  $d_n(t)$  分别是第  $n$  个样本的网络输出和期望输出.

雅各比行向量  $\mathbf{j}_n(t)$  中每一个元素的计算公式分别如下所示:

$$\begin{cases} \frac{\partial e_n(t)}{\partial \mathbf{w}(t)} = \left[ \frac{\partial e_n(t)}{\partial w_1(t)} \cdots \frac{\partial e_n(t)}{\partial w_l(t)} \cdots \frac{\partial e_n(t)}{\partial w_P(t)} \right], \\ \frac{\partial e_n(t)}{\partial w_l(t)} = -\frac{\partial y_n(t)}{\partial w_l(t)} = -v_l(t); \end{cases} \quad (14)$$

$$\begin{cases} \frac{\partial e_n(t)}{\partial \mathbf{c}_j(t)} = \left[ \frac{\partial e_n(t)}{\partial c_{1j}(t)} \cdots \frac{\partial e_n(t)}{\partial c_{ij}(t)} \cdots \frac{\partial e_n(t)}{\partial c_{kj}(t)} \right], \\ \frac{\partial e_n(t)}{\partial c_{ij}(t)} = -\frac{2w_j(t)v_j(t)[x_i(t) - c_{ij}(t)]}{\sigma_{ij}(t)}; \end{cases} \quad (15)$$

$$\begin{cases} \frac{\partial e_n(t)}{\partial \sigma_j(t)} = \left[ \frac{\partial e_n(t)}{\partial \sigma_{1j}(t)} \cdots \frac{\partial e_n(t)}{\partial \sigma_{ij}(t)} \cdots \frac{\partial e_n(t)}{\partial \sigma_{kj}(t)} \right], \\ \frac{\partial e_n(t)}{\partial \sigma_{ij}(t)} = -\frac{w_j(t)v_j(t)\|x_i(t) - c_{ij}(t)\|^2}{\sigma_{ij}(t)}. \end{cases} \quad (16)$$

LM 算法在学习过程中只能更新权值向量, 而 ILM 算法可以同时更新中心、宽度、权值 3 个参数, 并通过计算子矩阵的方式直接获取所有样本的拟海森矩阵和梯度矩阵, 避免了传统 LM 算法中对  $N \times K$  雅各比向量的乘法运算和存储, 所需存储空间减小了  $N$  倍, 降低了计算复杂度, 提高了计算速度, 工程适用性更强.

## 1.3 尖峰自组织模糊神经网络(SSOFNN)

Spiking 神经元能够有效模拟生物神经元之间信息随时间连续传递的过程, 其神经元处理机制以脉冲发放时间为编码方式, 将信息组织编码在神经元的同步、波动和脉冲发射时间中<sup>[18-20]</sup>. 其中, IF 模型是最常用的阈值点火模型, 神经元被当作一个积分电路来处理<sup>[21]</sup>, 模拟突触后神经元接收来自突触前神经元发放的脉冲刺激, 当膜电位达到阈值时发放脉冲, 在发放瞬间, 膜电位迅速下降至静息电位, 之后进入不应期<sup>[22]</sup>. 基于 IF 模型中神经元膜电位随时间变化的特点, 神经网络隐含层神经元的尖峰强度定义为

$$ss_j = -k_\tau \ln \left( \frac{k}{\sin(e^{\ln(\theta_j(t)) + A}) + \varepsilon} - 1 \right). \quad (17)$$

其中:  $\theta_j$  为第  $j$  个神经元的输出值;  $\varepsilon$  为小的正值常量;  $k$ ,  $k_\tau$  和  $A$  均为设定常值. 第  $j$  个隐含层神经元的尖峰强度与输出值 ( $0 < \theta_j < 1$ ) 变化曲线如图 2 所示, 当尖峰强度大于兴奋阈值时, 该隐含层神经元被激活并分裂产生新的神经元, 以提高神经网络的工作效率; 当尖峰强度小于静息电位时, 该神经元被认定为处于不活跃或不工作状态, 可以移除以获得紧凑的

网络结构.

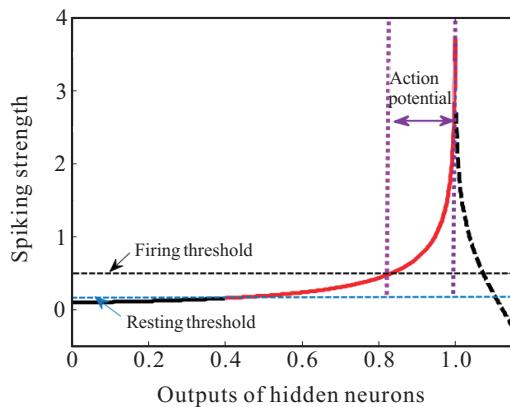


图2 隐含层神经元尖峰强度( $k = 2, k_\tau = 0.17, \Lambda = 7$ )

基于尖峰机制提出的模糊神经网络结构调整算法的增长-删减判别条件如下.

1) 增长阶段. 以隐含层神经元的尖峰强度和网络输出根均方误差作为增长判别指标, 当神经网络同时满足条件

$$ss_j(t) \geq ss_0, E(t) \geq E_d \quad (18)$$

时, 新的神经元将会增加到隐含层中. 其中:  $ss_0$  为兴奋阈值( $j = 1, 2, \dots, P$ ),  $E_d$  为训练误差目标, 均方根误差定义为

$$E(t) = \sqrt{\frac{1}{2N} \sum_{t=1}^{t=N} (d(t) - y(t))^2}. \quad (19)$$

新增神经元的初始参数设置如下:

$$\begin{cases} \mathbf{c}_{j-m'} = \alpha_{m'} \mathbf{c}_j + \beta_{m'} \mathbf{s}, \\ \sigma_{j-m'} = \alpha_{m'} \sigma_j, \\ w_{j-m'} = \gamma_{m'} w_j \theta_j(t) (N_{\text{new}} \theta_{j-m'}(t))^{-1}. \end{cases} \quad (20)$$

其中:  $\mathbf{c}_j$  和  $\sigma_j$  分别为当前第  $j$  个隐含层神经元的中心和宽度,  $\mathbf{c}_{j-m'}$  和  $\sigma_{j-m'}$  分别为新增的第  $m'$  个神经元的中心和宽度( $m = 1, 2, \dots, N_{\text{new}}$ );  $\alpha_{m'} \in [0.95, 1.05]$ ,  $\beta_{m'} \in [0, 0.1]$ ;  $w_{j-m'}$  和  $w_j$  分别为新增神经元和当前神经元的连接权值;  $\theta_{j-m'}$  为新增神经元的输出值.

2) 删减阶段. 修剪冗余神经元的判别条件如下:

$$ss_j(t) < ss_r. \quad (21)$$

其中  $ss_r$  为第  $j$  个隐含层神经元预先设定的静息阈值, 满足条件时该神经元将被移除. 与其欧氏距离最小的第  $j'$  个隐含层神经元参数更新规则如下:

$$\begin{cases} \mathbf{c}'_{j'} = \mathbf{c}_{j'}, \\ \sigma'_{j'} = \sigma_{j'}, \\ w'_{j'} = w_{j'} + w_j \theta_j(t) (\theta_{j'}(t))^{-1}. \end{cases} \quad (22)$$

$\mathbf{c}'_{j'}$ ,  $\mathbf{c}_{j'}$ ,  $\sigma'_{j'}$ ,  $\sigma_{j'}$ ,  $w'_{j'}$ ,  $w_{j'}$  分别为第  $j'$  个神经元在删减

机制执行前后的中心、宽度和连接权值.

## 2 实验数据采集及处理

### 2.1 数据来源

为了验证尖峰自组织模糊神经网络预测模型的有效性及实用性, 本文以北京某高校日需水量预测为例设计仿真实验, 所需用水量数据来自该校能源监管平台([nyjk.bjut.edu.cn](http://nyjk.bjut.edu.cn)), 气象数据来自中国气象数据网([data.cma.cn](http://data.cma.cn)), 该网站为中国气象局权威数据共享网站, 观测站为中国北京 54511. 获取需水量及辅助变量数据样本共 369 组, 其中 246 组作为神经网络模型训练样本, 123 组作为测试样本.

### 2.2 主成分分析

城市短期需水量预测研究的影响因素复杂多变, 与当地众多气象因素及日类型因素有关. 本文采集相关研究文献中使用过的 10 个气象因素(最高/最低/平均温度, 降水量, 露点, 相对湿度, 日照时长, 平均风速, 平均气压, 空气污染指数)及日类型(工作日常数 1, 周末常数 0.5, 法定节假日常数 0.3)作为分析样本, 采用主成分分析法对其进行线性变换降维处理, 提取特征变量, 选择主成分变量(PCs)分值作为 SSOFNN 预测模型的输入数据.

每个主成分变量根据其特征值计算解释性方差, 即贡献率, 前 5 个主成分变量的累积贡献率为 89.8529%, 代表其主成分分值包含原始数据约 90% 的信息, 如表 1 所示. 经过主成分分析, 输入变量由 11 个减少至 5 个, 在保证预测精度的前提下大大降低了计算复杂度.

表 1 主成分变量的统计信息

PCs	特征值	解释性方差/%	累积贡献率/%
PCs1	4.4288	40.1531	40.1531
PCs2	2.6022	23.5923	63.7455
PCs3	1.2232	11.0901	74.8355
PCs4	0.9850	8.9303	83.7658
PCs5	0.6715	6.0881	<b>89.8529</b>
PCs6	0.4963	4.4992	94.3931
PCs7	0.3245	2.9421	97.2951
PCs8	0.1848	1.6752	98.9704
PCs9	0.0742	0.6726	99.6431
PCs10	0.0350	0.3172	99.9603
PCs11	0.0044	0.0397	100.0000

### 2.3 参数设置

尖峰强度定义(17)中, 常数参量设定为  $k = 2$ ,  $k_\tau = 0.17$ ,  $\Lambda = 7$ , 与文献[22-23]保持一致; 增长判别条件(18)中, 设定兴奋阈值  $ss_0 = 0.29$ , 误差  $E_d = 0.005$ ; 删减判别条件(21)中, 静息阈值  $ss_r = 0.11$ , 阈值参数通过多次实验试凑获得. SSOFNN 的初始网络结构为 5-10-1.

### 3 仿真实验结果

采用SSOFNN模型对北京市某高校日需水量进行预测,实验结果如图3~图5所示。可以看出,本文提出的SSOFNN模型能够很好地预测短期需水量,跟踪精度高,性能稳定。

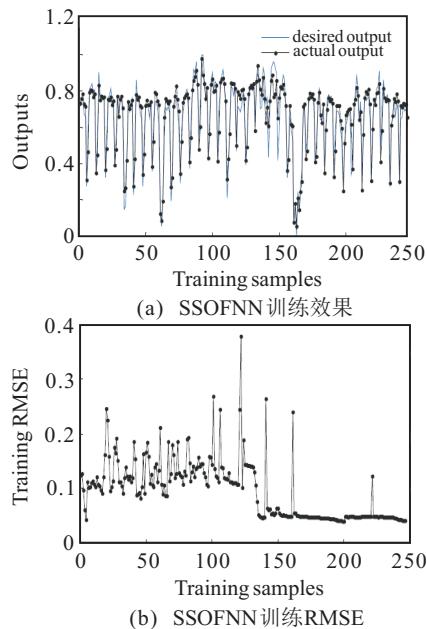


图3 SSOFNN训练结果

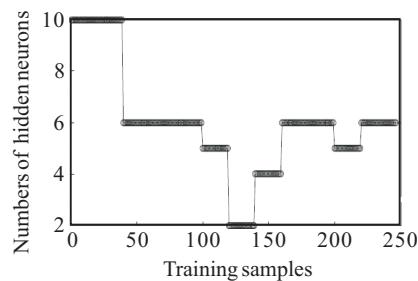


图4 SSOFNN隐含层神经元个数

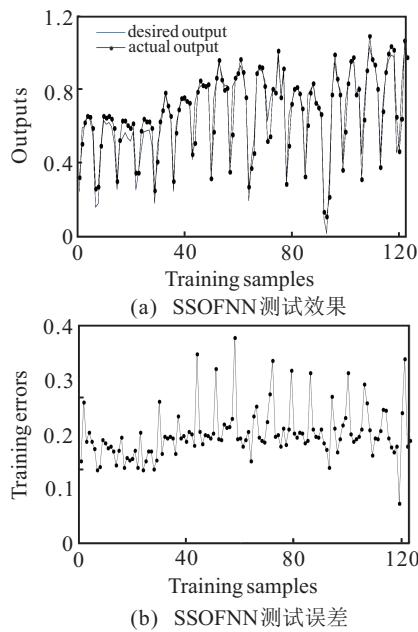


图5 SSOFNN测试结果

此外,基于尖峰机制的增长删减策略能够在网络学习过程中动态调整隐含层神经元个数,最终稳定在6个神经元。

为了进一步验证SSOFNN的有效性,本文设计了与其他神经网络预测方法的对比实验,包括改进LM模糊神经网络(ILM-FNN),LM模糊神经网络(LM-FNN),模糊神经网络(FNN),增长修剪模糊神经网络(GP-FNN),自组织径向基神经网络(SORBF)及动态模糊神经网络(DFNN)。选用RMSE作为对比指标,定义为

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{n=1}^N [d_n - y_n]^2}. \quad (23)$$

对比实验结果如表2所示。需要说明的是,ILM-FNN、LM-FNN、FNN等模型的隐含层神经元个数是在SSOFNN获得5-6-1的稳定结构后确定的,在实际应用中,固定结构的神经网络模型很难一次性确定最佳网络结构,需要花费大量时间通过试凑法获取。由表2可以看出,SSOFNN的预测性能在各方面的表现均较好,能够通过结构调整算法获得紧凑的网络结构,预测误差小,运行时间较少。与固定结构的ILM-FNN相比,由于增加了结构自组织过程,运行时间稍有增加。

表2 短期需水量预测对比实验结果

预测方法	隐含层神经元个数	RMSE		预测精度/%	运行时间/s
		训练	测试		
SSOFNN	6	0.0312	0.0498	96.34	6.37
ILM-FNN	8	0.0357	0.0558	92.41	3.19
LM-FNN	8	0.0536	0.0630	90.17	18.18
FNN	8	0.0499	0.0680	88.30	19.94
GP-FNN	9	0.0527	0.0670	87.85	—
SORBF	12	—	0.0623	—	—
DFNN	6	—	0.1127	82.37	—

### 4 结论

本文针对短期需水量预测非线性程度高、模糊性强、随机性大、影响因素复杂多变的特点,提出了基于尖峰机制的自组织模糊神经网络构建预测模型。采用主成分分析法对11个影响变量进行线性变换,提取5个主成分变量,使降维后的数据中尽可能多地包含原始数据的信息作为SSOFNN模型的输入数据。将基于Spiking神经元尖峰IF模型的增长-修剪机制应用到模糊神经网络中,结合改进LM学习算法,实现结构自调整和参数更新,解决了固定结构神经网络无法轻易确定最佳网络结构、无法在训练过程中自适应调整隐含层神经元数目问题,同时参数更新过程中计算流程的改进也大大提升了网络收敛

速度,使SSOFNN模型能够应用于大数据样本的实例工程。通过针对北京某高校的日需水量预测仿真实验验证,SSOFNN比其他神经网络方法预测精度更高,计算时间更短,具有很好的实用性。

### 参考文献(References)

- [1] 张雅君,刘全胜.需水量预测方法的评析与择优[J].中国给水排水,2001,17(7): 27-29.  
(Zhang Y J, Liu Q S. Analysis and selection of water demand forecasting methods[J]. China Water and Wastewater, 2001, 17(7): 27-29.)
- [2] 章征宝,陈朝东,张一刚.人工神经网络在城市用水量预测中的应用进展[J].给水排水,2007,33(增1): 110-115.  
(Zhang Z B, Chen C D, Zhang Y G. The headway made in application of artificial neural network in the forecasting of urban water consumption[J]. Water and Wastewater Engineering, 2007, 33(S1): 110-115.)
- [3] 李颖,张利伟.城市需水量预测模型的评价和选优研究[J].水利科技与经济,2016,22(6): 1-4.  
(Li Y, Zhang L W. Evaluation and selection exploration of city water consumption[J]. Water Conservancy Science and Technology and Economy, 2016, 22(6): 1-4.)
- [4] Jain A, Kumar Varshney A K, Joshi U C. Short-term water demand forecast modelling at IIT kanpur using artificial neural networks[J]. Water Resources Management, 2001, 15(5): 299-321.
- [5] 周艳春,李树平,赵子威,等.基于BP神经网络工具箱的城市短期用水量预测[J].给水排水,2015,41(增1): 375-377.  
(Zhou Y C, Li S P, Zhao Z W, et al. The prediction of urban short-term water consumption based on BP neural network toolbox[J]. Water and Wastewater Engineering, 2015, 41(S1): 375-377.)
- [6] 孙月峰,闫雅飞,张表志,等.基于T-S模型的模糊神经网络城市需水量预测方法研究[J].安全与环境学报,2013,13(2): 136-139.  
(Sun Y F, Yan Y F, Zhang B Z, et al. The urban water demand prediction method of fuzzy neural networks based on T-S model[J]. J of Safety and Environment, 2013, 13(2): 136-139.)
- [7] 卜义惠,赵洪宾,周建华.RBF网络预测城市用水量模型[J].中国给水排水,2003,19(8): 59-60.  
(Bu Y H, Zhao H B, Zhou J H. The prediction model of urban water consumption based on RBF network[J]. China Water and Wastewater, 2003, 19(8): 59-60.)
- [8] Chen S Y, Ji H L. Fuzzy optimization neural network approach for ice forecast in the inner mongolia reach of the yellow river[J]. Hydrological Sciences J, 2005, 50(2): 319-330.
- [9] 张伟,乔俊飞,李凡军.溶解氧浓度的直接自适应动态神经网络控制方法[J].控制理论与应用,2015,32(1): 115-121.  
(Zhang W, Qiao J F, Li F J. Direct adaptive dynamic neural network control for dissolved oxygen concentration[J]. Control Theory & Applications, 2015, 32(1): 115-121.)
- [10] Hsu C F, Cheng K H. Recurrent fuzzy-neural approach for nonlinear control using dynamic structure learning scheme[J]. Neurocomputing, 2008, 71(16/17/18): 3447-3459.
- [11] Xu Y, Zeng X, Han L, et al. A supervised multi-spike learning algorithm based on gradient descent for spiking neural networks[J]. Neural Networks, 2013, 43(4): 99-113.
- [12] Glackin C, Maguire L, Mcdaid L, et al. Synchrony: A spiking-based mechanism for processing sensory stimuli[J]. Neural Networks, 2012, 32(2): 26-34.
- [13] 杨静,徐彦,赵欣. Spiking神经元输入脉冲扰动敏感性研究[J].计算机工程与应用,2017,53(2): 6-11.  
(Yang J, Xu Y, Zhao X. Research on spiking neuron sensitivity to input perturbation[J]. Computer Engineering and Applications, 2017, 53(2): 6-11.)
- [14] 蔺想红,王向文,张宁,等.脉冲神经网络的监督学习算法研究综述[J].电子学报,2015,43(3): 577-586.  
(Lin X H, Wang X W, Zhang N, et al. Supervised learning algorithms for spiking neural networks: A review[J]. Acta Electronica Sinica, 2015, 43(3): 577-586.)
- [15] Han H G, Wang L D, Qiao J F, et al. A spiking-based mechanism for self-organizing RBF neural networks[C]. Int Joint Conf on Neural Networks. Beijing: IEEE, 2014: 3775-3782.
- [16] Xie T, Yu H, Hewlett J, et al. Fast and efficient second-order method for training radial basis function networks[J]. IEEE Trans on Neural Networks & Learning Systems, 2012, 23(4): 609-619.
- [17] Wilamowski B M, Yu H. Improved computation for levenberg-marquardt training[J]. IEEE Trans on Neural Networks, 2010, 21(6): 930-937.
- [18] Bohte S M. The evidence for neural information processing with precise spike-times: A survey[J]. Natural Computing, 2004, 3(2): 195-206.
- [19] Mehta M R, Lee A K, Wilson M A. Role of experience and oscillations in transforming a rate code into a temporal code[J]. Nature, 2002, 417(6890): 741-746.
- [20] Benchenane K, Peyrache A, Khamassi M, et al. Coherent theta oscillations and reorganization of spike timing in the hippocampal-prefrontal network upon learning[J]. Neuron, 2010, 66(6): 921-936.
- [21] Andrew A M. Spiking neuron models: Single neurons, populations, plasticity[J]. Kybernetes, 2003, 4(7/8): 277-280.
- [22] 王丽丹.基于尖峰自组织递归RBF神经网络的SVI软测量研究[D].北京:北京工业大学信息学部,2015.  
(Wang L D. Soft-computing model for sludge volume index based on spiking self-organizing recurrent RBF neural network[D]. Beijing: Faculty of Information Technology, University of Technology, 2015.)
- [23] Lu C, Han H G, Qiao J F, et al. Design of a self-organizing recurrent RBF neural network based on spiking mechanism[C]. The 35th Chinese Control Conf. Chengdu: IEEE, 2016: 3624-3629.

(责任编辑:孙艺红)