





用是直接传递到第二层。

第二层为模糊化层:用于计算输入变量对不同模糊集的隶属度.该层神经元的作用是将第一层的输入变量 $x_i$ 划分为 $m_i$ 个模糊度,因此共 $m$ 个神经元,  $m = m_1 + m_2 + \dots + m_n$ . 该层神经元与第一层神经元之间的连接权值都为 1, 隶属函数作为每个神经元的激活函数. 考

虑到高斯型隶属函数在处理非二值输入和空间映射方面具有较大优势<sup>[12]</sup>, 因此选择式 (1) 所示的高斯型隶属函数作为模型的隶属度函数:

$$\mu_{ij} = \exp\left(-\left(\frac{x_i - c_{ij}}{\sigma_{ij}}\right)^2\right), \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, m_i \quad (1)$$




图2 四层模糊神经网络结构

其中,  $\mu_{ij}$ 表示第 $i$ 个输入变量隶属与第 $j$ 个模糊集的隶属度函数;  $c_{ij}$ 为隶属函数 $\mu_{ij}$ 的中心值;  $\sigma_{ij}$ 为隶属函数 $\mu_{ij}$ 的宽度值.

第三层为模糊规则层,也称为“与”层,该层神经元的个数表示模糊规则数.每个神经元与上一层的 $m_i$ 个神经元中的一个节点相连,因此共 $R = m_1 + m_2 + \dots + m_n$ 个神经元,每个连接的权值为 1.每个神经元内部进行“与”操作,即“AND”操作,也就是求每个输入变量的隶属度的最小值,通过式 (2) 进行计算:

$$r_k = \min\{\mu_{1m_1}, \mu_{2m_2}, \dots, \mu_{nm_n}\} \quad k = 1, 2, \dots, R \quad (2)$$

第四层为反模糊化层,也称为“或”层,该层神经元的个数表示模糊集合的个数,本文中设备可能的状态.该层神经元与上一层神经元之间为全连接,权值 $\omega_{jk}$ 为需要调整的参数,神经元的输出值表示设备对这个状态的隶属度.

### 1.3 模糊神经网络学习算法

上述模糊神经网络的输出结果 $\tilde{y}$ 可以表示为式

(3)<sup>[13]</sup>:

$$\tilde{y} = \frac{\sum_{j=1}^R \sum_{k=1}^4 \omega_{jk} \cdot \prod_{i=1}^n \exp\left(-\left(\frac{x_i - c_{ij}}{\sigma_{ij}}\right)^2\right)}{\sum_{j=1}^R \prod_{i=1}^n \exp\left(-\left(\frac{x_i - c_{ij}}{\sigma_{ij}}\right)^2\right)} \quad (3)$$

采用均方误差函数作为该模糊神经网络的损失函数:

$$E = \frac{1}{n} \sum_{i=1}^n (\tilde{y} - y)^2 \quad (4)$$

由式 (5)–(7) 可以发现模型需要调整的参数有三种: $c_{ij}$ ,  $\sigma_{ij}$ 和 $\omega_{jk}$ , 这三种参数可以通过如下方法进行迭代更新:

$$c_{ij}^{t+1} = c_{ij}^t - \eta \frac{\partial E}{\partial c_{ij}^t} \quad (5)$$

$$\sigma_{ij}^{t+1} = \sigma_{ij}^t - \eta \frac{\partial E}{\partial \sigma_{ij}^t} \quad (6)$$

$$\omega_{jk}^{t+1} = \omega_{jk}^t - \eta \frac{\partial E}{\partial \omega_{jk}^t} \quad (7)$$

其中,  $\eta$ 表示学习率,  $t$ 表示迭代的次数.

### 1.4 模糊神经网络的适用性

针对电力自动化设备健康评估, 设备不同状态下不一定会出现某些显而易见的现象, 实际情况更多的是设备的某些参数偏高或者偏低, 而在设备健康评估时, 一般依靠经验来处理这些“偏高”或者“偏低”的模糊概念. 为解决此类具有模糊性以及参数难以定量描述的问题, 本文引入模糊理论进行处理. 模糊神经网络能够将输入进行模糊化处理然后进行模糊推理, 由于设备健康评估的影响因素如温度、占用率等具有很强的模糊性难以定量描述, 采用模糊神经网络将输入通过隶属函数进行处理, 从而可以进行定量描述, 很好的适应了设备健康评估问题.

## 2 基于模糊神经网络的电力调度自动化设备健康评估模型

在复杂系统中, 每个对象对于集合的隶属关系并不是明确的, 而是相对模糊的<sup>[14]</sup>. 电力调度自动化系统就是一个相对复杂的系统, 在这个系统中有数量庞大的IT设备, 设备的评价指标有很多, 如温度、网口状态、网络流量、内存使用率、硬盘使用率、CPU负荷率等<sup>[15]</sup>, 这些指标量更适合用模糊理论进行分析, 用模糊集合描述评价指标, 用数据指标的隶属度描述当前运行情况. 神经网络具有较强的自学习功能, 可根据历史数据学习结果来调整系统运行参数, 针对个体设备提供更准确的、更具个性化的健康评价. 本文采用的将模糊概念和神经网络结合的模糊神经网络模型可以极大提升电力调度自动化设备健康评估的效果.

将模糊神经网络模型应用到电力调度自动化设备健康评估的具体流程如图3所示, 具体步骤如下:

(1) 整理存储的设备6个月内的运行信息, 包括: CPU温度、硬盘温度、板卡温度、网口状态、网络流量、网络延迟、内存使用率、硬盘使用率、CPU使用率、网络丢包率、设备运行时间11个指标.

(2) 对设备的运行状态进行划分等级. 根据专业人员的分析和历史经验的总结, 将设备运行状态分为四个等级, 如表1所示.

(3) 通过计算设备各运行指标之间的皮尔逊相关系数, 删除部分冗余特征. 皮尔逊相关系数是衡量两个

随机变量之间线性相关程度的指标, 描述的是一种非确定性相关系数<sup>[16]</sup>, 计算公式如式(8)所示:

$$r = \frac{Cov(X, Y)}{\sigma_X \sigma_Y} = \frac{E((X - \mu_X)(Y - \mu_Y))}{\sigma_X \sigma_Y} \quad (8)$$

其中,  $Cov(X, Y)$ 表示随机变量  $X$  与  $Y$  的协方差矩阵,  $\mu_X, \mu_Y$ 分别表示随机变量  $X$  与  $Y$  的期望,  $\sigma_X, \sigma_Y$ 分别表示随机变量  $X$  与  $Y$  的方差. 相关系数  $r$  的取值范围为  $[-1, 1]$ , 绝对值越大说明两个随机变量的相关程度越高,  $r$  大于 0 表示正相关,  $r$  小于 0 表示负相关,  $r$  等于 0 表示不相关. 通过利用皮尔逊相关系数筛选最终用于训练模型的特征包括: CPU温度、硬盘温度、板卡温度、内存使用率、CPU使用率、网络丢包率、设备运行时间7个指标.

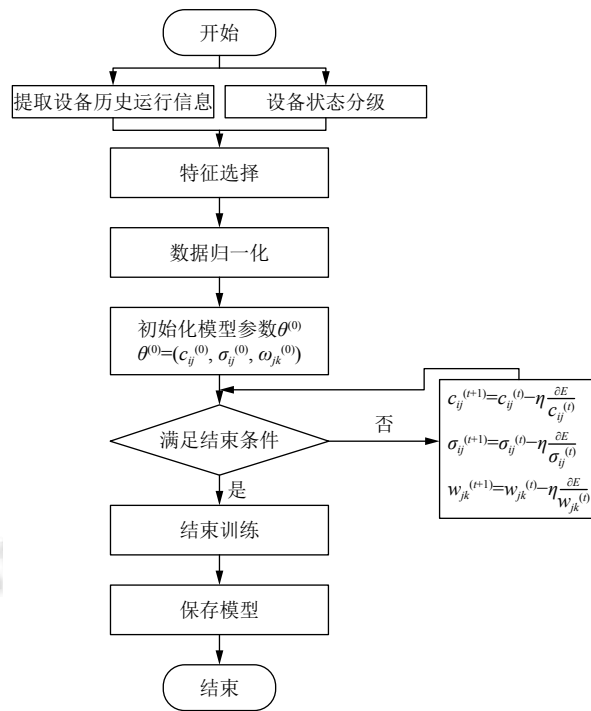


图3 电力调度自动化设备健康评估流程

表1 设备状态分级

| 运行状态 | 采取措施                            |
|------|---------------------------------|
| 正常   | 设备运行正常, 无需关注                    |
| 一般告警 | 设备出现轻微异常, 需留意观察                 |
| 严重告警 | 设备出现故障, 需要进行维修                  |
| 紧急告警 | 设备出现严重故障, 需要立即维修, 否则将损坏严重, 无法修复 |

(4) 因为各指标的值域不同, 因此需要对各指标进行归一化处理, 归一化计算公式如式(9)所示:

$$X_{\text{norm}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \quad (9)$$

其中,  $X_{\text{max}}$ 表示属性  $X$  的最大值,  $X_{\text{min}}$ 表示属性  $X$  的最小值. 各特征经过归一化处理, 数值范围都变换到  $[0, 1]$  之间, 这不仅可以消除量纲的差异还可以加速模型的收敛速度<sup>[17]</sup>.

(5) 初始化需要训练的模型参数, 主要包括三类参数:  $c_{ij}$ ,  $\sigma_{ij}$  和  $\omega_{jk}$ . 其中  $c_{ij}$  表示隶属函数的中心值,  $\sigma_{ij}$  为隶属函数的宽度值,  $\omega_{jk}$  为模糊规则层与反模糊层之间的连接权重.

(6) 更新模型参数直到满足模型训练的结束条件. 传统的模型终止条件有两种, 一种是当模型的输出值与真实值的误差小于设置的阈值时终止模型训练, 另一种是当迭代次数到达设置的次数时终止训练. 本文在此基础上增加模型训练的早停技巧, 即当模型在测试集上的误差增大时, 提前停止训练模型, 这样可以有效的避免模型的过拟合问题.

(7) 保存模型. 当模型训练完成之后需要将模型保存到文件中, 以便之后的模型使用. 采用 python 语言的 pickle 模块将模型序列化存储到本地文件中, 当使用模型时, 对序列化后的文件进行反序列化处理, 即可恢复原始模型进行使用.

### 3 实验分析

为了体现本文所用方法在电力自动化机房设备健康评估方面的有效性, 对传统神经网络的模型效果和本文所用模型效果进行了对比, 通过实验结果显示, 本文所采用模型的效果优于传统神经网络模型的效果.

#### 3.1 实验数据

利用 6 个月内共计 17 280 个设备运行数据进行模型的搭建, 将 17 280 个数据划分为训练集、验证集和测试集, 如表 2 所示. 每一条数据包含 4 个设备运行信息和 3 个设备硬件信息, 如表 3 所示.

表 2 数据集划分

|        | 训练集  | 验证集  | 测试集  |
|--------|------|------|------|
| 比例 (%) | 70   | 20   | 10   |
| 作用     | 模型训练 | 模型评估 | 模型择优 |

#### 3.2 实验结果

利用上述处理好的实验数据进行模型训练, 模型的训练集均方根误差和测试集均方根误差如图 4 所示,

纵坐标表示均方根误差 RMSE, 横坐标表示迭代次数, 可以看出模型的训练误差随着迭代次数的增加整体趋势是不断减小的, 但是测试误差先是不不断减小然后又有上升趋势, 其原因就是模型发生了过拟合, 因此需要提前终止模型训练, 根据结果分析, 选取迭代 75 轮时的模型作为最终的模型.

表 3 设备监测特征

| 设备运行信息  | 设备硬件信息 |
|---------|--------|
| CPU 使用率 | CPU 温度 |
| 内存使用率   | 硬盘温度   |
| 网络丢包率   | 板卡温度   |
| 设备运行时间  |        |




图 4 训练误差与测试误差

#### 3.3 实验对比

传统的三层 BP 神经网络, 激活函数为 Sigmoid 函数, 此类 BP 神经网络模型无法有效处理模糊输入信息同时无法利用已有的专家知识. 本文所采用的模糊神经网络模型将神经网络与模糊理论有机的结合起来, 不仅可以处理模糊信息同时具有较强的学习能力与自适应能力, 通过图 5 的结果对比可以看出本文所用的模糊神经网络模型效果要优于传统的三层 BP 神经网络模型, 说明模糊神经网络更加适用于电力自动化机房设备的健康评估.

### 4 结论与展望

本文首先介绍了模糊理论与神经网络的相关概念, 接着分析了将二者进行结合的模糊神经网络的原理, 然后将模糊神经网络应用到电力调度自动化系统设备健康评估中. 具体操作包括: 数据的收集、特征的选取以及模型的搭建, 并且比较了本文所建立的四层模糊神经网络模型和传统三层 BP 神经网络模型的效果, 实

验结果表明, 本文所建立的模型极大的提升了设备健康评估的效果, 针对 IT 设备可以给出更加精确的评估, 对于电力自动化机房的正常运行具有重要意义. 虽然本文所建立的模型效果优于传统的三层 BP 神经网络模型, 但是还有较大的提升空间, 比如选取更加有效的反映设备状态的特征, 选取更加合适的算法学习率和模型的初始参数, 这些问题都可以进一步提升模型对设备状态的评估效果, 这将是下一步需要进行完善的.




图5 传统神经网络与模糊神经网络结果对比

#### 参考文献

- 1 邓力, 马登武, 吴明辉. 基于健康状态监测与预测的装备维修决策方案. 计算机测量与控制, 2013, 21(11): 2895-2897, 2907. [doi: 10.3969/j.issn.1671-4598.2013.11.001]
- 2 褚健. 维修决策模型和方法的理论与应用研究[博士学位论文]. 杭州: 浙江大学, 2007.
- 3 许丽佳, 王厚军, 黄健国. CHMM 在发射机状态监测与健康评估中的应用研究. 电子科技大学学报, 2010, 39(6): 875-879, 890. [doi: 10.3969/j.issn.1001-0548.2010.06.015]
- 4 许丽佳, 黄健国, 王厚军. 基于 HMM 的模拟电路故障诊断方法. 计算机辅助设计与图形学学报, 2010, 22(7): 1215-1222.
- 5 张璇. 电力通信网络设备状态检修系统的开发与应用[硕士学位论文]. 北京: 华北电力大学, 2013.
- 6 倪丽, 宋世贤, 卢成光, 等. 电力变压器的实时状态评估. 电气技术, 2012, (10): 13-16. [doi: 10.3969/j.issn.1673-3800.2012.10.019]
- 7 马博, 董海鹰, 任伟. 基于模糊综合支持向量机的特高压变电站二次设备状态评估. 计算机系统应用, 2014, 23(9): 191-197. [doi: 10.3969/j.issn.1003-3254.2014.09.038]
- 8 Horikawa S, Furuhashi T, Uchikawa Y. On fuzzy modeling using fuzzy neural networks with the back-propagation algorithm. IEEE Transactions on Neural Networks, 1992, 3(5): 801-806. [doi: 10.1109/72.159069]
- 9 Yu W, Li XO. Fuzzy identification using fuzzy neural networks with stable learning algorithms. IEEE Transactions on Fuzzy Systems, 2004, 12(3): 411-420. [doi: 10.1109/TFUZZ.2004.825067]
- 10 张凯, 钱锋, 刘漫丹. 模糊神经网络技术综述. 信息与控制, 2003, 32(5): 431-435. [doi: 10.3969/j.issn.1002-0411.2003.05.011]
- 11 马秀会. 模糊神经网络研究综述[硕士学位论文]. 长春: 吉林大学, 2008.
- 12 薛善良, 杨佩茹, 周奚. 基于模糊神经网络的 WSN 无线数据收发单元故障诊断. 计算机科学, 2018, 45(5): 38-43.
- 13 姜长元. 模糊神经网络模型及其应用研究[硕士学位论文]. 南京: 南京师范大学, 2005.
- 14 高德华. 试论模糊化思维与复杂系统研究. 系统科学学报, 2007, 15(3): 64-67.
- 15 侯晓凯, 李师谦, 王杰琼, 等. 一种基于神经网络的网络设备故障预测系统. 山东理工大学学报, 2014, 28(6): 29-34. [doi: 10.3969/j.issn.1672-6197.2014.06.007]
- 16 周金治, 唐肖芳. 基于相关系数分析的脑电信号特征选择. 生物医药工程学杂志, 2015, 32(4): 735-739.
- 17 李航. 统计学习方法. 北京: 清华大学出版社, 2012: 20-30.