

# 基于改进贝叶斯神经网络的多联机故障诊断策略

曾宇柯, 陈焕新\*, 黄荣庚, 龚麒鉴

(华中科技大学能源与动力工程学院, 湖北 武汉 430074)

**[摘要]** 针对传统神经网络模型过拟合等问题, 本文提出了一种基于改进贝叶斯神经网络的多联机故障诊断策略, 该策略使用 LOF(local outlier factor)法剔除原始数据中的异常值, 并构建了 BR(Bayesian-regularization)神经网络以提高模型的泛化能力。实验通过多联机系统制冷剂充注量故障验证该策略的可行性。结果表明:较 BP(back-propagation)神经网络, LOF-BR 神经网络模型诊断性能增强, 整体检测率提高至 97%。充注过量误诊为充注不足的比率显著降低, LOF 法能有效剔除多联机系统异常值。

**[关键词]** : 多联机系统; 故障检测与诊断; 局部异常因子; 贝叶斯神经网络

## Fault Diagnosis Strategy Based on Improved Bayesian Regularization Neural Network for Variable Refrigerant Flow System

Zeng Yuke, Chen Huanxin\*, Huang Ronggeng, Gong Qijian

(School of Energy and Power Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

**[Abstract]** In order to solve the problem of overfitting of the traditional neural network, this paper proposes a variable refrigerant flow(VRF) system fault diagnosis strategy based on improved Bayesian Regularization neural network. The strategy uses the local outlier factor(LOF) method to eliminate outliers in the original data, and Build a Bayesian-regularization (BR) neural network to improve the generalization ability. The experiment verifies the feasibility of this strategy through the VRF system refrigerant charge failure, and optimizes the number of hidden layer nodes of the model. The results show that Compared with the back-propagation(BP) neural network model. The diagnostic performance of the LOF-BR neural network model was enhanced and the overall correct diagnosis rate (CDR) increased to 97%. The LOF-BR neural network model is significantly reduced due to overcharge misdiagnosis as undercharge. The LOF method can effectively eliminate outliers of VRF systems.

**[Keywords]:** Variable refrigerant flow system; Fault detection and diagnosis; local outlier factor; Bayesian-regularization neural network

---

\*陈焕新(1964-), 男, 教授, 博士。研究方向:制冷空调数据挖掘。联系地址:湖北省武汉市洪山区珞喻路 1097 号动力楼 309。E-mail: [chenhuanxin@tsinghua.org.cn](mailto:chenhuanxin@tsinghua.org.cn)。

基金项目: 国家自然科学基金资助项目(No. 51576074)。

## 0 引言

多联机系统由其能耗低、热舒适性高等优势广泛用于商场、公寓等场所<sup>[1]</sup>。2014年,多联机成为中央空调市场九大类增率最高,销售总量最大的产品,包括变频多联机和数码多联机在内,其市场占有率高达41%<sup>[2]</sup>。多联机系统在运行过程中可能发生诸多故障,如果不能及时发现和排除将会产生大量能耗、降低室内舒适性。因此,亟需开展适用于多联机系统的故障诊断策略。目前,制冷系统故障检测与诊断方法主要分为三种:基于定性经验知识、基于分析模型和基于数据驱动<sup>[3]</sup>。基于数据驱动的方法不依靠先验知识,仅通过分析大量数据发现变量和参量之间的固有联系,在复杂制冷系统的FFD中具备较高的应用前景。Zhu<sup>[4]</sup>等人提出了一种基于小波和分型神经网络的空气处理单元传感器故障诊断方法,该方法通过三层小波分析提取空气处理单元获取传感器故障特征。结果表明,较未分型的神经网络,该方法的检测率提高了15%。王江宇<sup>[5]</sup>等人通过数据集成和相关性分析处理压缩机故障数据,并建立基于CART算法的故障检测决策树模型,结果表明:基于CART算法的决策树模型能够对试验数据较好的分类且模型使用变量较少,鲁棒性较高。黄荣庚<sup>[6]</sup>等人通过构建合适的小波神经网络对多联机系统常见4种软故障进行诊断与预测。结果表明:小波神经网络对传感器故障具有良好的检测和诊断能力,较传感器精度下降,其对于偏移、漂移和完全失效三类故障具有更高的反应能力和敏感性。Fan<sup>[7]</sup>等人提出了一种用于本地空气处理单元(air handling unit, AHU)的自适应传感器故障诊断策略,该策略由两个BP神经网络构成AHU控制回路。仿真结果表明,该策略能准确的检测AHU系统传感器固定偏差故障和漂移故障。Shi<sup>[8]</sup>等人结合贝叶斯神经网络和ReliefF算法

进行多联机制冷剂充注量故障诊断,经测试集验证比较不同N-best特征数据子集的检测率。结果表明:较22个特征,使用6个特征时,模型已拥有较高的检测率,并且训练时间减少了98.8%。

## 1 LOF-BR多联机故障诊断策略

本文提出了一种基于改进贝叶斯神经网络的多联机故障诊断策略,使用LOF法剔除数据中的异常值,并构建BR神经网络提高模型泛化能力。笔者根据多联机制冷剂充注量故障数据,通过多次实验验证该策略故障诊断性能。

### 1.1 LOF算法

LOF算法<sup>[9]</sup>是一种典型的局部密度检测方法,它通过比较样本对象附近的密度与邻居附近的密度来判断异常程度,无需过多训练和预测数据的变化发展,可以检测未知的异常类型。因此运用LOF法进行多联机系统异常值检测具有一定的优越性。其具有以下定义<sup>[10]</sup>:

#### 1) k距离 $d_k(p)$

$p$ 和 $o$ 是数据集 $D$ 中的样本, $k$ 为任意自然数,数据 $p$ 和 $o$ 之间的距离 $d(p,o)$ 定义为 $p$ 和 $o$ 之间的欧式距离,对象 $P$ 的 $k$ 距离需满足以下两个条件:

至少存在不包含 $p$ 的 $k$ 个样本 $o'$ ( $o' \in D$ )使得 $d(p,o') \leq d(p,o)$ 。

至少存在不包含 $p$ 的 $k-1$ 个样本 $o'$ ( $o' \in D$ )使得 $d(p,o') < d(p,o)$ 。

#### 2) k邻域距离 $N_k(p)$

对于给定的数据 $p$ 和自然数 $k$ , $p$ 的 $k$ 邻域距离表示每一个与给定对象 $p$ 的距离小于 $d_k(p)$ 数据的集合。

#### 3) 可达距离 $reach-dist_k(p,o)$

如式1为 $d_k(p)$ 与 $d(p,o)$ 之间的较大值

$$reach-dist_k(p,o) = \max\{d_k(p), d(p,o)\} \quad (1)$$

#### 4) 局部可达密度 $lrd_k(p)$

表示  $p$  的  $k$  邻域内所有点到  $p$  平均可达距离的倒数,具体表达式如 2 所示。

$$lrd_k(p) = 1 / \left( \frac{\sum_{o \in N_k(p)} reach-dist_k(p,o)}{|N_k(p)|} \right) \quad (2)$$

#### 5) 局部异常因子 $lof_k(p)$

$$lof_k(p) = \sum_{o \in N_k(p)} \frac{lrd_k(o)}{lrd_k(p)} / |N_k(p)| \quad (3)$$

为  $p$  点邻域的局部可达密度与  $p$  点局部可达密度之比的平均数,反应了数据的异常程度。

### 1.2 贝叶斯神经网络

虽然 BP 神经网络得到了广泛的应用,但他本身仍然存在限制和不足<sup>[11]</sup>,其中较为突出的是 BP 神经网络易出现过拟合、泛化能力不足。正则化方法在原函数的基础上增加一个约束项使函数求解稳定<sup>[12]</sup>,从而较好的避免了此类问题。贝叶斯神经网络模型性能函数如式 4 所示。

$$F = \beta E_D + \alpha E_W \quad (4)$$

式 4 中  $E_D$  为均方误差平方和,  $E_W$  表示网络权值平方和,  $\alpha$ 、 $\beta$  为贝叶斯正则化系数。在常见的正则化方法中,比例系数  $\alpha$  和  $\beta$  难以确定。Mackay<sup>[13]</sup> 的研究表明,对于贝叶斯神经网络,贝叶斯正则化系数可在网络训练过程中自调节至最优,  $\alpha$  和  $\beta$  的自更新公式如式 5、6 所示:

$$\alpha = \frac{\gamma}{2E_W} \quad (5)$$

$$\beta = \frac{n-\gamma}{2E_D} \quad (6)$$

式 5、6 中  $\gamma = N - \alpha \text{Trace}(A)^{-1}$ , 为有效权值数,体现网络的实际规模,  $N$  是所有网络参数的个数。  $A$  为性能函数  $F$  的 Hessian 矩阵。

贝叶斯神经网络通常由输入层、隐含层和输出层三层网络构成,本研究中多联机系统贝叶斯神经网络拓扑结构如图 1 所示,多联机系统特征作为输入向量,隐含层节点数由经验公式 7 计算,输出向量为 3 个故障类别:充注不足、充注适中、充注过量。

$$N_h = 2N_i + 1 \quad (7)$$

式 7 中  $N_h$  为隐含层节点数,  $N_i$  为输入层神经元数。




图 1 多联机贝叶斯神经网络拓扑结构

### 1.3 制冷剂充注量实验设置

实验测量了多联机系统不同制冷剂充注量的工作性能,图 2 为实验多联机系统示意图,

该多联机系统由 5 个室内单元和 1 个室外单元组成,系统工质为 R410A,标准充注量 9.9kg,实验温度传感器和压力传感器的位置如图布置。

多联机系统在中温制冷工况下运行，室外单元干球温度 35℃，5 个室内单元全部运行，干球温度均为 26℃，温度实验均在标准测温室内完成，具体温度设置如表 1 所示。

表 1 系统运行工况表

测试模式	室内温度(℃)		室外温度(℃)	
	干球	湿球	干球	湿球
中温制冷	26	19	35	24

实验制冷剂充注量水平从 63.0%至 130.0% 共 9 个级别，分为充注不足、充注适中、充注过量三类，具体如表 2 所示。对于每一种实验工况，风机转速(1 个室内风机和 5 个室外风机)认为保持不变，实验通过调节压缩机转速和膨胀阀开度使制冷剂流量匹配冷凝负荷，压缩机运行频率变化范围为 0 至 90。当制冷剂充注不足或充注过量时，多联机系统依旧可以稳定运行。

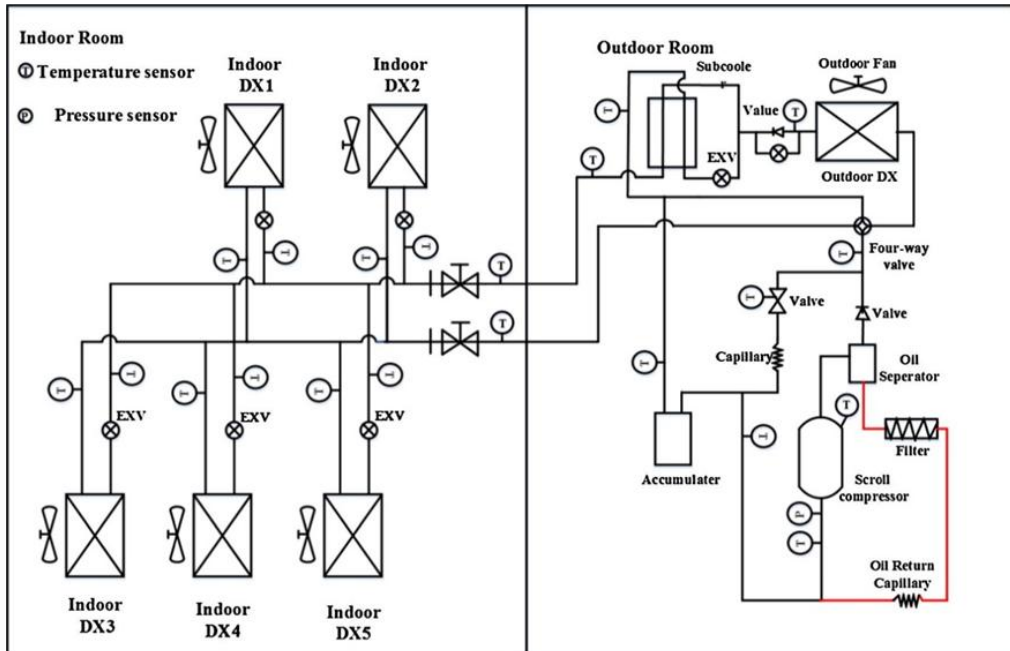


图 2 多联机系统示意图

表 2 制冷剂充注及其对应类别

编号	充注量(%)	故障类别
1	63	充注不足
2	75	充注不足
3	80	充注不足
4	85	充注适中
5	95	充注适中
6	105	充注适中
7	110	充注适中
8	120	充注过量
9	130	充注过量

实验按照 PID 控制规则将两个房间的温度条件调整至表 1 所示。数据采集系统每隔 15s

收集一次数据，每次实验至少进行 45min，共选取了 3831 个样本数据，其中充注不足样本 1963 个、充注适中样本 1120 个、充注过量样本 748 个。实验参考 Sun<sup>[14]</sup>等人的研究选取了压缩机排气温度、压缩机外壳温度、室外风机温度、压缩机电压和冷凝温度五个特征变量进行故障诊断，特征详情如表 3 所示。

表 3 特征变量表

编号	变量名称	缩写
1	压缩机排气温度	$T_{dis}$
2	压缩机外壳温度	$T_{shell}$
3	室外风机温度	$T_{fan}$

4	压缩机电压	$U_{com}$
5	冷凝温度	$T_{comd}$

### 1.4 LOF-BR 多联机故障诊断模型

图 3 为 LOF-BR 神经网络模型的多联机故障诊断逻辑图，其由三部分组成：

- 1) 异常值检测：计算每个样本的 LOF 值，剔除 LOF 值大于 LOF 阈值的样本，保留可能的正常数据；
- 2) 模型建立：将剔除异常值后的数据随机分为 70% 的训练集和 30% 的测试集，标准化处理后，训练集输入 BR 神经网络模型，进行制冷剂泄漏故障诊断模型训练；
- 3) 故障诊断：将测试数据输入训练好的故障诊断模型，比较该模型与 BP 神经网络模型的诊断结果，发掘可能的改进措施。

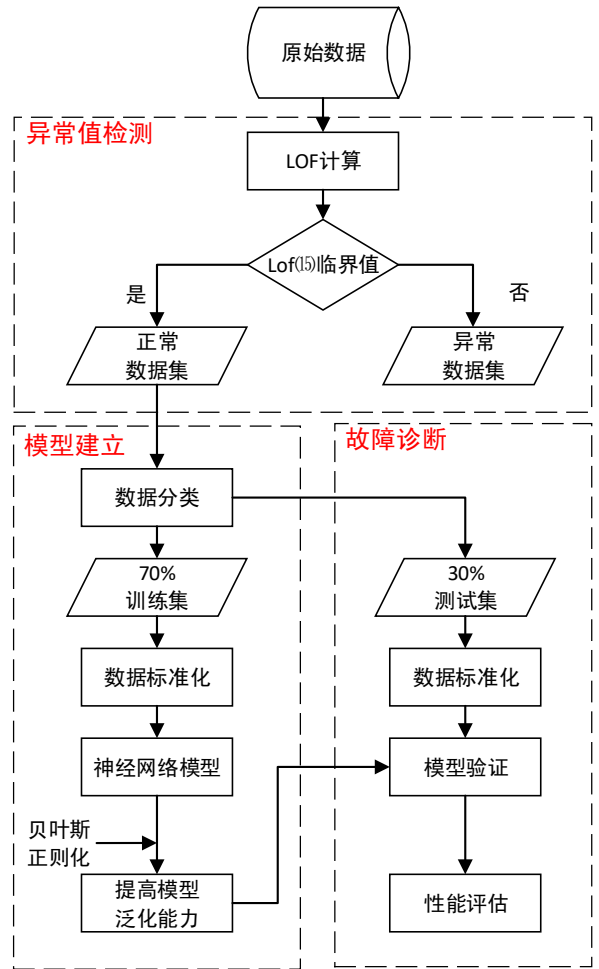


图 3 LOF-BR 神经网络故障诊断逻辑图

## 2 多联机故障诊断结果

本文将采用整体检测率和单类检测率这两种标准比较 LOF-BR 神经网络模型和 BP 神经网络模型的优劣。

### 2.1 LOF 法剔除多联机异常值

图 4 为制冷剂充注故障 LOF 值密度分布图，结果表明，大多数制冷剂充注量样本数据的 LOF 值接近 1，但仍有少量数据偏离 1 值较大，其中充注不足、充注适中、充注过量三类数据最大 LOF 值分别为 3.67、6.33 和 4.41。经过大量实验，本文选取 LOF 阈值为 1.38。

剔除约 7%的可能异常值后，三类故障的样本数目如表 4 所示。

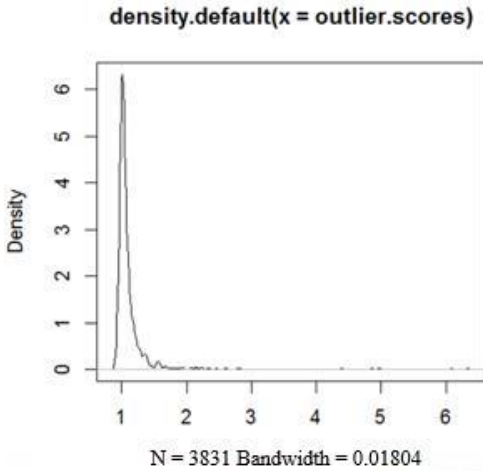


图 4 LOF 值密度分布图

表 4 制冷剂充注及其对应类别

样本数目	BP	LOF-BR
充注不足	1963	1833
充注适中	1120	1060
充注过量	748	674

## 2.2 制冷剂充注量故障诊断结果分析

图 5 是两种神经网络模型总体检测率和各类检测率的对比图，可以看到，较 BR 神经网络，LOF-BR 神经网络在各类检测率上均有较大提高。

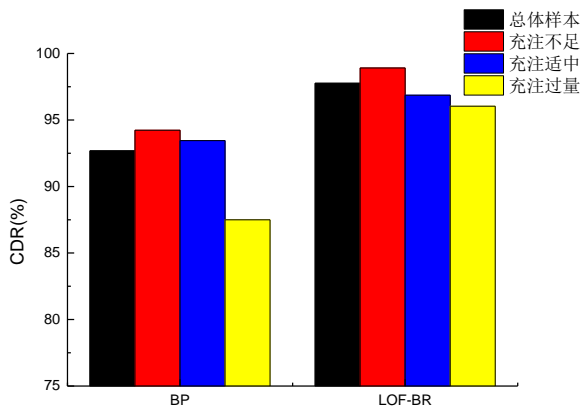


图 5 LOF-BR 神经网络故障诊断逻辑图

在 BP 神经网络模型中，充注过量的诊断率远远低于充注不足和充注适中的诊断率，仅为

87.50%，由于多联机系统异常值的影响，干扰了模型对充注过量问题的拟合效果。表 5 为 BP 神经网络模型的混淆矩阵，可以看到 BP 神经网络将充注过量误诊为充注不足的比率高达 9.82%，这些异常值为实际运行过程中，外界冲击使得多联机运行工况发生震荡，膨胀阀自行调节开度产生。

表 5 BP 三类故障混淆矩阵

		预测充注量 (%)		
		不足	适中	过量
实际充注量 (%)	不足	94.23	3.90	1.87
	适中	1.19	93.45	5.36
	过量	9.82	2.68	87.50

表 6 为 LOF-BR 神经网络模型的混淆矩阵，较 BP 神经网络模型，该方案的误诊率显著降低，其中网络将充注过量误诊为充注不足的比率由 9.82%降低至 3.46%，将充注适中误诊为充注过量的比率由 5.36%降低至 2.83%，充注过量的检测率由 87.50%增长至 96.04%，同时 LOF-BR 神经网络模型的整体诊断性能提升，充注不足与充注适中的检测率均有明显增加。LOF-BR 模型的整体检测率由 93.26%提高至 97.76%，模型的泛化能力增强。

表 6 LOF-BR 三类故障混淆矩阵

		预测充注量 (%)		
		不足	适中	过量
实际充注量 (%)	不足	98.91	0.36	0.73
	适中	0.31	96.86	2.83
	过量	3.46	0.50	96.04

## 3 结论

本研究将 LOF 法与贝叶斯神经网络结合，用于多联机系统故障检测与诊断，并通过制冷剂充注量故障验证该方案的诊断性能，结论如下：

1) 较 BP 神经网络模型，LOF-BR 模型充注过量误诊为充注不足的比率显著降低，剔除异常值能有效提高模型检测率。

2) 较 BP 神经网络模型, LOF-BR 模型三类充注量故障检测率均得到提升, 整体检测率提高到 97% 以上, 模型泛化能力提高, 具有更强的诊断性能。

LOF-BR 神经网络对多联机系统具有良好的诊断性能, 对防止故障恶化维持设备正常运行具有重要的意义。

#### 参考文献:

- [1] 王江宇, 陈焕新, 刘江岩, 等. 基于 PCA-DT 的多联机制冷剂充注量故障诊断[J]. 华中科技大学学报(自然科学版), 2016, 44(7):1-4.
- [2] 荆华乾, 高恩元, 于志慧, 等. 2014 年度中国制冷行业发展分析报告[J]. 制冷技术, 2015, 37(a01):1-82.
- [3] HaorongLi, Braun J. A Methodology for Diagnosing Multiple Simultaneous Faults in Vapor-Compression Air Conditioners[J]. Hvac & R Research, 2007, 13(2):369-395.
- [4] Zhu Y, Jin X, Du Z. Fault diagnosis for sensors in air handling unit based on neural network pre-processed by wavelet and fractal[J]. Energy & Buildings, 2012, 44(1):7-16.
- [5] 王江宇, 陈焕新, 李冠男, 等. 基于 CART 算法的多联机压缩机回液故障检测[J]. 制冷与空调, 2017, 17(4):55-60.
- [6] 黄荣庚, 陈焕新, 李冠男, 等. 基于小波神经网络的多联式空调机组传感器故障检测和诊断[J]. 制冷与空调, 2018(2).
- [7] Fan B, Du Z, Jin X, et al. A hybrid FDD strategy for local system of AHU based on artificial neural network and wavelet analysis[J]. Building & Environment, 2010, 45(12):2698-2708.
- [8] Shi S, Li G, Chen H, et al. Refrigerant charge fault diagnosis in the VRF system using Bayesian artificial neural network combined with ReliefF filter[J]. Applied Thermal Engineering, 2016, 112:698-706.
- [9] 陈溟. 基于模糊局部离群因子(LOF)的信用卡欺诈检测研究[J]. 金融理论与实践, 2016(10):54-57.
- [10] Knorr E M, Ng R T, Tucakov V. Distance-based outliers: algorithms and applications[J]. Vldb Journal, 2000, 8(3-4):237-253.
- [11] 冯中艳. 基于数据统计特性的 HVAC 系统故障检测方法研究[D]. 天津大学, 2015.
- [12] 王智文. 贝叶斯神经网络与 FTIR 技术在多气体定量分析中的应用研究[D]. 中北大学, 2011.
- [13] Mackay D. Bayesian Interpolation[J]. Neural Computation, 2008, 4(3):415-447.
- [14] Sun S, Li G, Chen H, et al. A hybrid ICA-BPNN-based FDD strategy for refrigerant charge faults in variable refrigerant flow system[J]. Applied Thermal Engineering, 2017, 127.