

Analog Circuit Fault Diagnosis Using Transfer Learning and LSSVM^{*}

ZHUANG Chengcheng, YI Hui, ZHANG Jie, LIU Shuai

(College of Electrical Engineering & Control Science, Nanjing 211816, China)

Abstract: When diagnosing analog circuit faults using data-driven approaches, if the target fault set is insufficient, the diagnostic performance will decrease significantly. To solve the above problem, a novel fault diagnosis method based on transfer learning and least square support vector machine (TL-LSSVM) was proposed. This method transfers related sample set into the target fault training set effectively. In the diagnosis, wavelet coefficients of the output signals are firstly extracted as features. Then, error penalty term of the source domain auxiliary data is added to the objective function of the LSSVM classifier, and constructs a new diagnosis model. Finally, testing samples are imported to the new model for classification. The performance of the proposed approach was validated with a filter circuit. In the experiment, the proposed approach made the accuracy of single and double fault diagnosis reach 97.2% and 95.7%, respectively. and show a significant improvement of diagnostic accuracy in situation of insufficient target fault samples.

Key words: analog circuit; fault diagnosis; transfer learning; least square support vector machine; auxiliary data
EEACC: 1285; 0170L doi: 10.3969/j.issn.1005-9490.2019.03.025

基于迁移学习 LSSVM 的模拟电路故障诊断^{*}

庄城城, 易 辉^{*}, 张 杰, 刘 帅

(南京工业大学电气工程与控制科学学院, 南京 211816)

摘 要: 采用数据驱动方法进行模拟电路故障诊断时, 在目标故障数据较少的条件下, 诊断效果显著下降。针对该问题, 提出一种基于 TL-LSSVM 的模拟电路故障诊断方法。该方法将相关的源域数据迁移至目标故障训练集, 首先提取输出信号的小波系数作为特征数据, 然后在 LSSVM 分类器的目标函数中增加源域辅助数据的误差惩罚项, 构建出新的诊断模型。以滤波电路为诊断实例, 实验结果表明, 该方法使单、双故障诊断正确率分别达到 97.2% 和 95.7%, 显著提高了诊断正确率。

关键词: 模拟电路; 故障诊断; 迁移学习; 最小二乘支持向量机; 辅助数据

中图分类号: TN707; TP181

文献标识码: A

文章编号: 1005-9490(2019)03-0668-06

模拟电路的诊断测试比数字电路更加复杂, 电路的非线性、元件的容差性等问题对故障诊断技术提出了更高的要求^[1]。随着人工智能的快速发展, 在模拟电路故障诊断中, 众多学者应用了神经网络^[2]、模糊理论^[3]、支持向量机 SVM (Support Vector Machine)^[4]等技术, 取得了较好的研究成果。

模拟电路故障诊断主要集中在特征提取和模式分类这两个问题上^[5]。在特征提取方面, 文献^[6]提出在小波变换中, 通过类间距离的可分性测度选择最优小波基, 提取较好的故障特征, 从而提高了故障分

类的准确率和效率。在故障模式分类中, 文献^[7]中将马氏距离与 LSSVM 相结合用于模拟电路的故障诊断, 在准确率和诊断时间上获得很好的效果。但是这些方法未能克服传统机器学习的局限性: 当训练和测试数据不是相同的数据分布时, 训练得到的模型就需要持续更新; 训练数据不足时也不能得到很好的分类模型^[8]。在实际应用中, 模拟电路受到制造工艺、噪声、热效应等因素的影响, 数据之间存在一定的分布差异, 这会影响模型分类器的分类诊断效果。

迁移学习作为机器学习领域的一个新的分支,

项目来源: 国家自然科学基金项目 (61503181)

收稿日期: 2018-08-20 修改日期: 2018-10-05

近年来受到更多学者的关注和研究。文献[9]将迁移学习的思想应用到结构紊乱识别中,使识别率在样本数不足的情况下得到提高。本文利用模拟电路在不同激励信号下的故障数据来帮助目标数据分类,提出了一种基于迁移学习最小二乘支持向量机 TL-LSSVM (Transfer Learning-Least Square Support Vector Machine) 的模拟电路故障诊断模型。该方法将小波分解后的特征向量导入改进后的 LSSVM 分类器中进行训练和预测,从而提高诊断精度。

1 迁移学习原理

1995 年机器学习领域开展了 NIPS 专业讨论会“Learning to Learn”,此后迁移学习研究进入快速发展期。迁移学习的目的是从一个或多个源任务中提取知识,并将知识应用于目标任务。与多任务学习相比,迁移学习最主要的是目标任务,而不是同时学习所有的源任务和目标任务^[10]。

迁移学习主要包括域 D 和任务 T 两个概念^[11]。 D 由特征空间 X 和边缘概率分布 $P(X)$ 两部分组成,其中 $X = \{x_1, \dots, x_n\} \in X$ 。对一个给定的域, T 同样由两部分组成,标签空间 y 和预测函数 $f(\cdot)$ 。

给定一个有标签的源域数据 D_s 和对应的源任务 T_s , 一个标签数极少的目标域 D_t 和对应的学习任务 T_t 。目的是通过 D_s 和 T_s 的知识迁移到 D_t , 从而提高目标预测函数的性能 ($D_s \neq D_t$ 或 $T_s \neq T_t$)。

2 TL-LSSVM 算法模型

2.1 最小二乘支持向量机

LSSVM 利用等式约束条件代替 SVM 标准算法中的不等式约束条件^[12],使得优化问题的求解变为通过 Kuhn-Tucker 条件得到的一组线性方程组的求解,对于一组输入样本: $\{(x_i, y_i)\}, i=1, \dots, n, x_i \in R^n, y_i = \pm 1$, LSSVM 利用非线性映射将输入数据映射到一个高维特征空间,使输入空间中的非线性函数估计问题转化为高维特征空间中的线性函数估计问题,其判别函数为 $f(x) = w^T \varphi(x) + b$ 。

2.2 TL-LSSVM 算法

基于辅助数据集的迁移算法,利用与目标集相似的辅助数据集来提高分类模型的准确度。给定 $\{(x_i, y_i)\}_{i=1}^n$ 为目标样本数据, $\{(x_i, y_i)\}_{i=n+1}^m$ 为源域相似样本数据。TL-LSSVM 方法在原 LSSVM 优化问题的基础上,在目标式中增加源域辅助数据的误差惩罚项^[13],实现知识从源域到目标域间的迁移。改进后的目标函数可表示为:

$$\begin{cases} \min J(w, \xi) = \frac{1}{2} w^T w + \frac{C_t}{2} \sum_{i=1}^n \xi_i^2 + \frac{C_s}{2} \sum_{i=n+1}^{n+m} \xi_i^2 \\ \text{s.t. } y_i(w^T \varphi(x_i) + b) = 1 - \xi_i, \quad i = 1, 2, \dots, n, \dots, n+m \end{cases} \quad (1)$$

式中: C_t, C_s 分别为目标域和源域数据集的惩罚参数, ξ_i 为预测误差。

引入 Lagrange 乘子,导出式(1)的对偶规划:每个等式约束与拉格朗日乘子 $\alpha_i \geq 0$ 相乘,再加入目标函数,建立 Lagrange 函数:

$$L(w, b, \xi_i, \alpha_i) = J(w, \xi) - \sum_{i=1}^{n+m} \alpha_i [y_i(w^T \varphi(x_i) + b) - 1 + \xi_i] \quad (2)$$

由取极值的必要条件,对 L 分别求各变量的偏导数,并令其为零,得到

$$\begin{cases} \frac{\partial L}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^{n+m} \alpha_i y_i \varphi(x_i) \\ \frac{\partial L}{\partial \xi_i} = 0 \Rightarrow \alpha_i = \begin{cases} C_t \xi_i, i = 1, 2, \dots, n \\ C_s \xi_i, i = n+1, \dots, n+m \end{cases} \\ \frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^n \alpha_i y_i = 0 \\ \frac{\partial L}{\partial \alpha_i} = 0 \Rightarrow y_i(w^T \varphi(x_i) + b) - 1 + \xi_i = 0 \end{cases} \quad (3)$$

消去变量 w 和 ξ_i , 可得矩阵方程:

$$\begin{bmatrix} \Omega + \frac{1}{C} & Y \\ Y^T & 0 \end{bmatrix} \begin{bmatrix} \alpha \\ b \end{bmatrix} = \begin{bmatrix} e \\ 0 \end{bmatrix} \quad (4)$$

式中: $\Omega_{ij} = y_i y_j K(x_i, x_j)$, $K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j)$ 为核函数, $Y = [y_1, \dots, y_{n+m}]^T$ 和 $e = [1, \dots, 1]^T$ 是 $n+m$ 维的列向量, $C = \text{diag}[C_t, \dots, C_t, C_s, \dots, C_s]$ 。

由式(4)可以求得一组参数 α 和 b , 从而得到 TL-LSSVM 决策函数表达式

$$f(x) = \text{sgn} \left[\sum_{i=1}^l \alpha_i y_i K(x, x_i) + b \right] \quad (5)$$

高斯核函数对于数据中的噪音有着较好的抗干扰能力,在本文中采用高斯核作为 TL-LSSVM 的核函数,表达式为: $K(x, x_i) = \exp[-\|x - x_i\|^2 / (2\sigma^2)]$, 其中 σ 为高斯核宽参数。

3 TL-LSSVM 故障诊断流程

本文针对故障诊断样本不完备问题,提出一种基于 TL-LSSVM 的故障诊断方法。该方法将不同激励条件下生成的故障数据作为源域样本集参与到故障分类器的训练中,可有效提高分类准确率,进而达到提高诊断准确率的目的。

基于本文所提方法的模拟电路故障诊断详细流

程如图 1 所示。




图 1 TL-LSSVM 故障诊断流程

主要有以下几个步骤:

Step 1 对待测电路施加不同的激励信号,采集各模式下的输出响应并做信号预处理。

Step 2 利用不同激励条件下目标故障数据帮助学习,提取故障特征构建源域和目标域训练样本集。通过训练集训练得到目标函数,然后用来预测新数据的标签。设训练数据集和测试数据集分别为 T 和 S :

$$\begin{cases} T_t = \{(x_i^t, y_i^t)\}, & i=1, 2, \dots, n \\ T_s = \{(x_i^s, y_i^s)\}, & i=1, 2, \dots, m \\ T = \{T_t, T_s\} = \{(x_i, y_i)\}, & x_i = \begin{cases} x_i^t & i=1, \dots, n \\ x_i^s & i=n+1, \dots, n+m \end{cases} \\ S = \{x_j^t\}, & j=1, 2, \dots, k \end{cases} \quad (6)$$

式中: T_t 和 T_s 分别是目标和辅助故障训练数据集, x_i 是第 i 个样本的特征向量, y_i 是对应的故障类别标签, n 和 m 分别是目标和辅助故障训练数据集的样本个数,一般 $n \leq m$ 。测试集选取的是与训练集不同的目标故障数据。

Step 3 输入训练样本,训练 TL-LSSVM 分类器。模拟电路故障诊断属于多分类问题,需要对二分类的 TL-LSSVM 分类器进行多分类推广,采用导向无环图方式来构建。对 k 类分类问题构造 $k(k-1)/2$ 个二分类器,将这所有的二分类器排列于 $k-1$ 层导向无环图决策结构中,进行 $k-1$ 次决策就能实现多分类。

Step 4 输入测试样本,对故障数据进行分类,验证模型的诊断性能。

4 实验验证

本文以 Sallen-Key 带通滤波器电路作为诊断实

例。按照上述方法进行测试并对比分析结果。仿真实验以 Multisim 12 作为实验平台,算法的实现由 MATLAB 2014a 完成。

4.1 电路故障设置

Sallen-Key 带通滤波器电路的拓扑结构如图 2 所示,元件的标称值已在图中标出。电阻和电容的容许误差分别设置为标称值的 5% 和 10%,高于或低于标称值的 50% 设置为故障值。通过灵敏度分析,选择 C_1 、 C_2 、 R_2 、 R_3 进行测试分析,构成单故障和双故障的模式设置。具体故障设置如表 1 和表 2 所示,NF 表示电路无故障。




图 2 Sallen-Key 带通滤波电路图

表 1 Sallen-Key 带通滤波器电路单故障模式

编号	故障类别	标称值	故障值
F0	NF	—	—
F1	C_1	5 nF	7.5 nF
F2	C_1	5 nF	2.5 nF
F3	C_2	5 nF	7.5 nF
F4	C_2	5 nF	2.5 nF
F5	R_2	1 kΩ	1.5 kΩ
F6	R_2	1 kΩ	0.5 kΩ
F7	R_3	3 kΩ	4.5 kΩ
F8	R_3	3 kΩ	1.5 kΩ

表 2 Sallen-Key 带通滤波器电路双故障模式

编号	故障类别	标称值	故障值
F0	NF	—	—
F1	C_1, C_2	5 nF, 5 nF	7.5 nF, 7.5 nF
F2	C_1, C_2	5 nF, 5 nF	2.5 nF, 2.5 nF
F3	C_1, R_2	5 nF, 1 kΩ	7.5 nF, 1.5 kΩ
F4	C_1, R_2	5 nF, 1 kΩ	2.5 nF, 0.5 kΩ
F5	C_1, R_3	5 nF, 3 kΩ	7.5 nF, 4.5 kΩ
F6	C_1, R_3	5 nF, 3 kΩ	2.5 nF, 1.5 kΩ
F7	C_2, R_2	5 nF, 1 kΩ	7.5 nF, 1.5 kΩ
F8	C_2, R_2	5 nF, 1 kΩ	2.5 nF, 0.5 kΩ
F9	C_2, R_3	5 nF, 3 kΩ	7.5 nF, 4.5 kΩ
F10	C_2, R_3	5 nF, 3 kΩ	2.5 nF, 1.5 kΩ
F11	R_2, R_3	1 kΩ, 3 kΩ	1.5 kΩ, 4.5 kΩ
F12	R_2, R_3	1 kΩ, 3 kΩ	0.5 kΩ, 1.5 kΩ

4.2 提取故障特征

采用 5 V, 1 kHz 的正弦波和 10 μ s, 5 V 的脉冲波激励被测电路, 输出节点 3 为可测节点, 对输出响应采样, 获取源域和目标域的原始故障信息。对表 1 中的每类故障进行 50 次 Monte Carlo 分析, 采用 5 层 Haar 小波对输出响应进行分解, 提取小波系数的最大绝对值作为故障特征。每种故障模式下的目标域样本随机分成两部分, 其中 30 组数据结合源域样本

参与分类器训练, 另外 20 组数据作为测试样本验证分类器的性能。

4.3 诊断结果及分析

图 3 和图 4 给出了单故障和双故障模式下部分响应曲线, 单故障模式中 F1、F5、F7 的频率曲线相近, 对诊断效果影响较大。双故障模式中 F1 和 F9、F2 和 F10、F3 和 F11 曲线波形相近, 容易导致误分类。




图 3 单故障幅频曲线图






图 4 双故障幅频曲线图

使用粒子群算法对 TL-LSSVM 模型的惩罚参数 C 和核参数 σ 进行优化。设初始种群大小为 20, 最大迭代次数为 200, 惯性权重 $w_{\max} = 0.9, w_{\min} = 0.4$, 学习因子 $c_1 = 1.5, c_2 = 1.7$, 建立 TL-LSSVM 故障诊断模型, 对测试样本进行分类识别。

单故障诊断结果如图 5(a) 所示, F1 和 F5 的诊断正确率分别为 85%、90%, 其余故障的诊断正确率为 100%, 总体故障诊断正确率为 97.2%。双故障诊断结果如图 5(b) 所示, 总体故障诊断正确率为 95.7%。



(a) 单故障诊断结果




(b) 双故障诊断结果

图 5 单、双故障诊断结果图


4.4 对比实验

对传统机器学习 LSSVM 算法和本文基于迁移学习理论的 TL-LSSVM 方法的性能进行比较, 取目标域中的 20 组数据做测试样本, 当训练样本从小到大变化时, 使用迁移学习和非迁移学习的诊断结果如图 6 所示。

从图 6 中可以看出, 当用于训练的目标样本数不足时, 传统 LSSVM 方法, 即非迁移学习模型训练出的分类器诊断效果低于迁移学习分类模型。随着目标样本数增加, 迁移学习的效果随之降低, 单、双故障模式下, 迁移学习使分类准确率的提高值分别从 16.11% 降为 0 和从 9.82% 降为 1.08%。当目标样本数达到 30 以上, 两者的分类效果基本一致。因此, 在该实验情况下, 所提方法在目标数据不足时体现出更优越的分类性能。



(a) 单故障模式对比



(b) 双故障模式对比

图 6 迁移学习与非迁移学习的比较

5 结论

本文提出了一种基于 TL-LSSVM 的模拟电路故障诊断方法。在传统机器学习算法中引入迁移学习的理论, 将与目标相关的源域数据有效迁移至目标故障训练集, 辅助构建故障分类器, 泛化了算法模型对数据分布的要求, 解决了样本数据不足引起的分类效果不佳的问题。通过 Sallen-Key 带通滤波电路的仿真实验, 所提方法对单故障和双故障的分类识别率都优于标准 LSSVM 方法。

参考文献:

- [1] 孙永奎, 陈光福, 李辉. 基于可测性分析和支持向量机的模拟电路故障诊断[J]. 仪器仪表学报, 2008, 29(6): 1182-1186.
- [2] Yin S R, Chen G J, Xie Y L. Wavelet Neural Network Based Fault Diagnosis in Nonlinear Analog Circuits [J]. Journal of Systems Engineering and Electronics, 2006, 17(3): 521-526.
- [3] Wang Y H, Jiang A M, Cheng R, et al. A Novel Approach of Analog Circuit Sensor Fault Diagnosis Using Fuzzy Integrated Binary Support Vector Machines [J]. Sensor Letters, 2013, 11(11): 2174-2176.
- [4] Zhang C L, He Y G, Yuan L F, et al. A Novel Approach for Diagnosis of Analog Circuit Fault by Using GMKL-SVM and PSO [J]. Journal of Electronic Testing, 2016, 32(5): 531-540.
- [5] 何威, 何怡刚, 罗旗舞, 等. 基于连续小波奇异熵的模拟电路故障诊断新方法[J]. 电子测量与仪器学报, 2017, 31(12): 1967-1973.
- [6] Song G M, Li Q, Luo G, et al. Analog Circuit Fault Diagnosis Using Wavelet Feature Optimization Approach [C]//IEEE International Conference on Electronic Measurement & Instruments, 2016, 1:


- 119-124.
- [7] Long B, Xian W X, Li M, et al. Improved Diagnostics for the Incipient Faults in Analog Circuits Using LSSVM Based on PSO Algorithm with Mahalanobis Distance[J]. Neurocomputing, 2014, 133: 237-248.
- [8] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 35(2): 238-244.
- [9] 刘小明, 翟蕾蕾, 朱婷. 基于迁移学习的乳腺结构紊乱异常识别[J]. 计算机工程与设计, 2017, 38(9): 2530-2535.
- [10] Pan S J, Yang Q. A Survey on Transfer Learning[J]. IEEE Transactions on Knowledge & Data Engineering, 2010, 22(10): 1345-1359.
- [11] 冯志刚, 张学娟. 基于 LS-SVM 和 SVM 的气动执行器故障诊断方法[J]. 传感技术学报, 2013, 26(11): 1610-1616.
- [12] Karl Weiss, Taghi M Khoshgoftaar, Ding Ding Wang. A Survey of Transfer Learning[J]. Journal of Big Data, 2016, 3(1): 9.
- [13] 陈超, 沈飞, 严如强. 改进 LSSVM 迁移学习方法的轴承故障诊断[J]. 仪器仪表学报, 2017, 38(1): 33-40.



庄城城(1992-),男,汉族,江苏南通人,南京工业大学,硕士研究生,主要研究方向为电子电路的故障诊断, 15151869818@163.com;



易 辉(1984-),男,汉族,江苏常州,南京工业大学,博士,副教授,主要研究方向为数据驱动故障诊断、复杂系统健康预测与管理 and 模式识别技术, jsyihui@126.com;



张 杰(1991-),男,汉族,江苏宿迁,南京工业大学,硕士研究生,主要研究方向为光伏组件故障诊断;



刘 帅(1994-),男,汉族,江苏徐州,南京工业大学,硕士研究生,主要研究方向为航天器姿态跟踪协同控制。